

MODELO PARA DETERMINAR EL ESTADO COGNITIVO EN PACIENTES COMATOSOS MEDIANTE EL REGISTRO DE LA ACTIVIDAD BIOELÉCTRICA CEREBRAL

**ALEJANDRO CARDONA MURILLO
ESTEBAN VELÁSQUEZ RENDÓN**



**ESCUELA DE INGENIERÍA DE ANTIOQUIA
INGENIERÍA MECATRÓNICA
ENVIGADO
2013**

MODELO PARA DETERMINAR EL ESTADO COGNITIVO EN PACIENTES COMATOSOS MEDIANTE EL REGISTRO DE LA ACTIVIDAD BIOELÉCTRICA CEREBRAL

**ALEJANDRO CARDONA MURILLO
ESTEBAN VELÁSQUEZ RENDÓN**

Trabajo de grado para optar al título de Ingeniería Mecatrónica

**Alejandro Peña Palacio
Ingeniero Mecánico
MSc.
PH.D.**



**ESCUELA DE INGENIERÍA DE ANTIOQUIA
INGENIERÍA MECATRÓNICA
ENVIGADO
2013**

AGRADECIMIENTOS

A nuestras familias por siempre estar allí y apoyarnos en todos los aspectos.

A la universidad EAFIT, por habernos facilitado el Emotiv, que fue una herramienta indispensable para la recolección de datos.

A nuestro director de trabajo de grado, Alejandro Peña Palacio, por el tiempo y los aportes brindados que posibilitaron el desarrollo del proyecto.

A la Escuela de Ingeniería de Antioquia por formarnos como Ingenieros Mecatrónicos.

TABLA DE CONTENIDO

RESUMEN.....	12
ABSTRACT	13
INTRODUCCIÓN.....	14
1. PRELIMINARES	15
1.1. Planteamiento del Problema.....	15
1.2. Objetivos del proyecto	15
1.2.1. Objetivo general	15
1.2.2. Objetivos específicos.....	15
1.3. Marco teórico.....	16
1.3.1. Función cerebral en diferentes desordenes cerebrales.....	18
1.3.1.1. La conciencia, el estado de alerta y la excitación	20
1.3.1.2. Definiciones clínicas.....	20
1.3.2. Artefactos biológicos.....	22
1.3.4. P300	23
1.3.5. Bandas de frecuencia	24
1.3.6. Emotiv EPOC Headset	24
1.3.7. Procesamiento de los datos.....	25
1.3.7.1. Adquisición del RAW DATA	26
1.3.7.2. Preprocesamiento de los Datos	27
1.3.7.2.1. Filtro Pasa Bajo y Pasa Alto	27
1.3.7.2.2. Remoción de la línea base	28
1.3.7.2.3. Análisis de Componentes Independientes (ICA).....	28
1.3.7.3. Transformada de Fourier	30

1.3.7.4.	Periodograma	30
1.3.7.5.	Periodograma Modificado	30
1.3.8.	Redes Neuronales Artificiales	31
1.3.8.1.	Redes Neuronales con conexión hacia adelante (Proceso Feedforward)	31
1.3.8.1.1.	Perceptrón Multicapa	31
1.3.8.1.1.1.	Aprendizaje en el perceptrón multicapa	32
1.3.8.1.2.	Red Neuronal de Base Radial	33
1.3.8.1.2.1.	Aprendizaje en la red de base radial	34
1.3.8.1.2.2.	Funciones de Activación	35
1.3.8.2.	Regla Delta Generalizada (proceso backpropagation)	35
1.3.8.3.	Función de salida	36
1.3.8.4.	Criterios de Parada	36
2.	PROCEDIMIENTO METODOLÓGICO	37
3.	DESARROLLO DEL MODELO	39
3.1.	Caracterizar los patrones de entrada que muestran la presencia de conciencia:	39
3.1.1.	Investigar los diferentes tipos de headsets:	39
3.1.2.	Lenguajes de Programación	41
3.1.3.	Factores De Error:	42
3.1.4.	Estímulos Adecuados:	43
3.1.4.1.	Banda Delta vs Estado Mental	45
3.1.4.2.	Banda Theta vs Estado Mental	46
3.1.4.3.	Banda Alpha vs Estado Mental	48
3.1.4.4.	Banda Beta vs Estado Mental	50
3.1.4.5.	Banda Gamma vs Estado Mental	51
3.1.4.6.	Resumen del Análisis ANOVA	53

3.2.	Diseño del modelo	53
3.2.1.	Obtener los registros regulares de pacientes sanos:	53
3.2.2.	Plantear el modelo para clasificar los patrones de activación cerebral:.....	56
3.3.	Desarrollo del modelo para clasificar los patrones de activación cerebral:.....	58
3.3.1.	Red perceptrón multicapa (MLP)	58
3.3.2.	Red de Base Radial (RBF)	62
3.3.3.	Resumen general de las redes neuronales artificiales empleadas	66
4.	VALIDACIÓN DEL MODELO	67
4.1.	Red perceptrón multicapa (MLP)	67
4.2.	Red de base radial (RBF)	68
4.3.	Resumen general de la validación de las redes neuronales artificiales	69
4.4.	Validación del modelo con pacientes inconscientes.....	70
5.	PROTOCOLO DE EVALUACIÓN DE LOS PACIENTES	71
6.	DISCUSIÓN DE RESULTADOS	73
7.	CONCLUSIONES Y CONSIDERACIONES FINALES.....	74
	BIBLIOGRAFÍA.....	75
	ANEXOS.....	78

LISTA DE TABLAS

<i>Tabla 1. Rangos de amplitud y frecuencia de algunos artefactos biológicos. Es importante resaltar que estos datos fueron tomados lo más cerca posible del origen de la actividad eléctrica.</i>	23
<i>Tabla 2. Rango de frecuencia de las ondas cerebrales.</i>	24
<i>Tabla 3. Especificaciones técnicas del Emotiv Epoc.</i>	25
<i>Tabla 4. Ejemplo de los datos relevantes del RAW DATA.</i>	26
<i>Tabla 5. Comparación entre headsets comerciales.</i>	41
<i>Tabla 6. Potencia Promedio en cada Banda de Frecuencia vs Estado Mental.</i>	44
<i>Tabla 7. Resumen Estadístico Banda Delta vs Estado Mental.</i>	45
<i>Tabla 8. ANOVA para Delta por Estado Mental.</i>	45
<i>Tabla 9. Grupos Homogéneos Delta vs Estados Mentales.</i>	45
<i>Tabla 10. Diferencia Significativa entre Estados Mentales.</i>	45
<i>Tabla 11. Resumen Estadístico Banda Theta vs Estado Mental.</i>	46
<i>Tabla 12. ANOVA para Theta por Estado Mental.</i>	47
<i>Tabla 13. Grupos Homogéneos Theta vs Estados Mentales.</i>	47
<i>Tabla 14. Diferencia Significativa entre Estados Mentales.</i>	47
<i>Tabla 15. Resumen Estadístico Banda Alpha vs Estado Mental.</i>	48
<i>Tabla 16. ANOVA para Alpha por Estado Mental.</i>	48
<i>Tabla 17. Grupos Homogéneos Alpha vs Estados Mentales.</i>	49
<i>Tabla 18. Diferencia Significativa entre Estados Mentales.</i>	49
<i>Tabla 19. Resumen Estadístico Banda Beta vs Estado Mental.</i>	50
<i>Tabla 20. ANOVA para Beta por Estado Mental.</i>	50
<i>Tabla 21. Grupos Homogéneos Beta vs Estados Mentales.</i>	50
<i>Tabla 22. Diferencia Significativa entre Estados Mentales.</i>	50

Tabla 23. Resumen Estadístico Banda Gamma vs Estado Mental.....	51
Tabla 24. ANOVA para Gamma por Estado Mental.	51
Tabla 25. Grupos Homogéneos Gamma vs Estados Mentales.	52
Tabla 26. Diferencia Significativa entre Estados Mentales.	52
Tabla 27. Resumen del Análisis ANOVA de los diferentes casos	53
Tabla 28. Frecuencia vs Potencia.	55
Tabla 29. Potencia en las Bandas de Frecuencia	56
Tabla 30. Base de Datos de las series de datos para el entrenamiento y validación de la red perceptrón multicapa.	59
Tabla 31. Parámetros asociados al proceso de aprendizaje de la red perceptrón multicapa.	59
Tabla 32. Criterios de parada de la red perceptrón multicapa.	60
Tabla 33. Salidas aprendidas por la red perceptrón multicapa sobre las pruebas de entrenamiento. En verde se muestran los aciertos y en rojo los desaciertos.	61
Tabla 34. Resultados sobre el entrenamiento de la red perceptrón multicapa con las series de datos de aprendizaje propuestas.	62
Tabla 35. Base de Datos de las series de datos para el entrenamiento y validación de la red de base radial.	63
Tabla 36. Parámetros asociados al proceso de aprendizaje de la red de base radial.	63
Tabla 37. Criterios de parada de la red de base radial.	64
Tabla 38. Salidas aprendidas por la red de base radial sobre las pruebas de entrenamiento. En verde se muestran los aciertos y en rojo los desaciertos.	65
Tabla 39. Resultados sobre el entrenamiento de la red de base radial con las series de datos de aprendizaje propuestas.	66
Tabla 40. Resultados sobre la validación de la red perceptrón multicapa con las series de datos destinados para validar el modelo.	68
Tabla 41. Validación sobre el 50% de pruebas restantes de la red perceptrón multicapa.	68
Tabla 42. Resultados sobre la validación de la red de base radial con las series de datos destinados para validar el modelo.	69
Tabla 43. Validación sobre el 50% de pruebas restantes de la red de base radial.	69

LISTA DE FIGURAS

<i>Figura 1. Sistema de posicionamiento de electrodos “Diez-Veinte” (Navarro, 2010).....</i>	<i>17</i>
<i>Figura 2. Diagrama de flujo de la lesión cerebral y el coma. El estado vegetativo sigue típicamente luego del coma; después de un mes se usa el término de “estado vegetativo persistente”; luego de tres meses para una lesión no traumática o un año para una lesión traumática algunos autores usan el término de “estado vegetativo permanente”, el cual implica que no existen probabilidades de recuperación (Steven Laureys, 2004).....</i>	<i>19</i>
<i>Figura 3. Excitación y estado de alerta, los dos componentes de la conciencia en el coma, estado vegetativo, estado de mínima conciencia y síndrome de enclaustramiento (Steven Laureys, 2004).....</i>	<i>19</i>
<i>Figura 4. Señal y localización de la medida de P3a y P3b (Bernt Schiele, 2010).....</i>	<i>23</i>
<i>Figura 5. Distribución 10-20 empleada para los electrodos del Emotiv Epoc (Emotiv, 2013).</i>	<i>25</i>
<i>Figura 6. Señal eléctrica del electrodo AF3.....</i>	<i>27</i>
<i>Figura 7. Filtros pasa bajo y pasa alto.</i>	<i>27</i>
<i>Figura 8. Línea de base.</i>	<i>28</i>
<i>Figura 9. Análisis de Componentes Independientes (Tzyy-Ping Jungl, 1998).</i>	<i>29</i>
<i>Figura 10. Artefacto de ojos. El mapa auto-organizado de la actividad cerebral mostrado en la esquina superior izquierda es un típico ejemplo de un artefacto ocasionado por un parpadeo. El grafo de la esquina superior derecha muestra la actividad cerebral desde 1ms antes de ocurrido el evento hasta 2 ms después. En la parte inferior se muestra el espectro de potencia para el artefacto en cuestión. (Neuroscience, 2013).....</i>	<i>29</i>
<i>Figura 11. Arquitectura del perceptrón multicapa (Pedro Isasi Viñuela, 2004).</i>	<i>32</i>
<i>Figura 12. Arquitectura de las redes neuronales de base radial (Pedro Isasi Viñuela, 2004).</i>	<i>34</i>
<i>Figura 13. Gráfico Caja y Bigotes de Banda Delta vs Estado Mental.</i>	<i>46</i>
<i>Figura 14. Gráfico Caja y Bigotes de Banda Theta vs Estado Mental.</i>	<i>48</i>
<i>Figura 15. Gráfico Caja y Bigotes de Banda Alpha vs Estado Mental.</i>	<i>49</i>
<i>Figura 16. Gráfico Caja y Bigotes de Banda Beta vs Estado Mental.</i>	<i>51</i>
<i>Figura 17. Gráfico Caja y Bigotes de Banda Gamma vs Estado Mental.....</i>	<i>52</i>

<i>Figura 18. RAW DATA.....</i>	<i>54</i>
<i>Figura 19. Ejemplo de un segmento de datos erróneo recortado.</i>	<i>54</i>
<i>Figura 20. Frecuencia vs Potencia de la Señal (Neuroscience, 2013).</i>	<i>55</i>
<i>Figura 21. Disposición de las Pruebas Recolectadas.....</i>	<i>57</i>
<i>Figura 22. Arquitectura de la red perceptrón multicapa.....</i>	<i>58</i>
<i>Figura 23. Iteraciones vs Error Cuadrático Medio de la red perceptrón multicapa.....</i>	<i>60</i>
<i>Figura 24. Arquitectura de la red de base radial.....</i>	<i>62</i>
<i>Figura 25. Iteraciones vs Error Cuadrático Medio de la red de base radial.</i>	<i>64</i>
<i>Figura 26. Interfaz gráfica de las dos redes neuronales.....</i>	<i>82</i>

LISTA DE ANEXOS

<i>Anexo 1. Cronograma.....</i>	<i>78</i>
<i>Anexo 2. Presupuesto.....</i>	<i>79</i>
<i>Anexo 3. Programación en Visual Basic de la Red Perceptrón Multicapa</i>	<i>82</i>
<i>Anexo 4. Programación en Visual Basic de la Red de Base Radial</i>	<i>86</i>
<i>Anexo 5. Programación en MATLAB</i>	<i>89</i>

RESUMEN

En el presente trabajo se expone el desarrollo de un modelo computacional que tiene como objetivo inferir el estado cognitivo de pacientes en estados derivados del coma mediante el registro de la actividad bioeléctrica cerebral.

Inicialmente se identificaron los diferentes desórdenes cerebrales relacionados con la conciencia, basándose en las definiciones clínicas y los aspectos metodológicos de la muerte cerebral, el coma, el estado vegetativo, el estado de mínima conciencia y el síndrome de enclaustramiento.

Se propuso el estudio de la actividad cerebral mediante electroencefalografía, haciendo uso de un headset comercial óptimo para la tarea. Luego se exploraron los temas de los artefactos biológicos (actividad eléctrica que no es generada por el cerebro) y sus posibles causas, los potenciales relacionados con eventos (ERP) y las bandas de frecuencia en donde se hallan las diferentes ondas cerebrales que permiten analizar el estado cognitivo. Conociendo estos factores, se determinó la necesidad de preprocesar los datos obtenidos (filtros requeridos) y de implementar un análisis de componentes independientes (ICA) para la remoción de artefactos en la búsqueda de interpretar sus dinámicas de comportamiento correctamente.

En el desarrollo del estudio se realizaron pruebas a pacientes de control aplicando estímulos auditivos de modo que se produjesen en los pacientes patrones de activación bien definidos y distinguibles entre sí. Para tal fin, se les indicó que imaginaran en un primer caso situaciones relajantes y en un segundo caso situaciones frustrantes. Los registros obtenidos fueron preprocesados y posteriormente ingresados en una red neuronal artificial de identificación y clasificación; se empleó la mitad de las muestras para el proceso de aprendizaje de la red neuronal y la otra mitad para el proceso de validación del modelo.

Se evaluaron dos tipos de redes neuronales con el fin de determinar cuál de las dos era la más efectiva en el proceso de clasificación de los dos estados mentales propuestos. Las redes evaluadas fueron: red perceptrón multicapa y red de base radial, siendo esta última la que arrojó el mejor porcentaje de clasificación.

El resultado obtenido del proceso de validación indicó que el modelo logra inferir el estado cognitivo en por lo menos cuatro de cada cinco casos, suponiendo una posibilidad de implementación futura del modelo en pacientes con detrimento cognitivo. De acuerdo a lo anterior, se propuso un protocolo de evaluación para los pacientes en estados derivados del coma.

Palabras Claves: BCI, EEG, ICA, ERP, IC, ERS, ERD, Artefactos Biológicos.

ABSTRACT

We propose the development of a computational model that aims to infer the cognitive state of patients in any derived state of coma using the bioelectrical brain activity registry.

Initially, we identified the different brain disorders related to the consciousness, focusing in the clinical definitions and the methodological issues of brain death, coma, vegetative state, minimally conscious state and the locked-in syndrome.

We proposed the use of electroencephalography to study the brain activity, making use of an optimal commercial headset for the task. Furthermore, we explored the topics of the biological artifacts (electrical activity that is not generated by the brain) and its possible causes, the event related potentials (ERP) and the frequency bands where the different brain waves, that allow the analysis of the cognitive state, are found. Knowing this factors, we determined the need of preprocess the obtained data (required filters) and the implementation of an independent component analysis (ICA) to remove the artifacts in the pursuit of interpreting its behavioral dynamics correctly.

In the development of this study, we made assessments to control patients applying auditory stimuli that produced well defined and distinguishable activation patterns in them. For this purpose we pointed them to imagine, in first case, relaxing situations and in second case, frustrating situations. The obtained registries were preprocessed and entered into an identification and classification artificial neural network; we used half of the samples for the learning process of the neural network and the other half for the validation of the model.

We evaluated two types of neural networks with the purpose of determining which of the two was the most effective in the classification process of the mental states proposed. The evaluated networks were: the multilayer perceptron network and the radial basis function network, being the last one the one that dropped the best classification percentage.

The achieved results of the validation process indicated that the model can infer the cognitive state of at least four out of five cases, assuming the possibility of a future implementation of the model in patients with cognitive detriment. According to the above, we proposed an assessment protocol for patients in any derived state of coma.

Keywords: BCI, EEG, ICA, ERP, IC, ERS, ERD, Biological Artifacts.

INTRODUCCIÓN

La conciencia, desde el aspecto médico, se define como la capacidad de reaccionar ante diferentes estímulos, ya sean visuales, auditivos, entre otros, que le permiten a la persona interactuar con el entorno. Una forma de evaluar el estado de conciencia de un individuo es aplicándole un estímulo y analizando la respuesta que éste presenta. El inconveniente radica cuando el individuo no tiene la capacidad para responder de forma normal o evidente por alguna razón, como es el caso de los pacientes en estados derivados del coma, y es allí en donde se requiere una conexión directa con su cerebro en busca de una respuesta.

Para llevar a cabo la conexión directa con este tipo de pacientes, existen interfaces que permiten una conexión física y funcional humano-máquina como las BCI (Brain-Computer Interface); éstas poseen la ventaja de no requerir de una interacción de movimiento corporal compleja para lograr la comunicación.

Las BCI obtienen el registro de la actividad bioeléctrica cerebral, que mediante un tratamiento, permiten analizar y determinar factores relevantes del paciente como las magnitudes de voltaje de los diferentes electrodos y la potencia de las ondas cerebrales, posibilitando la inferencia del estado cognitivo que presenta un determinado paciente mediante la determinación de los patrones de activación que ciertas tareas cognitivas producen.

Existen diferentes herramientas comerciales y de fácil acceso que posibilitan esta interacción cerebro-computador mediante electroencefalografía, como lo son el Emotiv y el Neurosky; sin embargo se deben considerar diversos factores de error que se pueden tener en la recolección de datos que son independientes de estos, como por ejemplo: reflejos involuntarios, estados temporales de adormecimiento y estados de inconciencia farmacológicamente inducidos.

La estimación del estado cognitivo en el presente estudio, se enfoca en la población de pacientes en estados derivados del coma, como es el estado vegetativo, el estado de mínima conciencia y el síndrome de enclaustramiento, en los cuales se evidencia una dificultad enorme para identificar el grado de conciencia que poseen. Es por esta razón que se planteó un modelo que permite inferir la presencia de conciencia en este tipo de pacientes empleando los principios de la inteligencia computacional.

1. PRELIMINARES

1.1. PLANTEAMIENTO DEL PROBLEMA

¿Cómo inferir el nivel de conciencia de los pacientes en estado comatoso a partir de su actividad cerebral frente a ciertos estímulos?

Las estrategias de identificación de los niveles de conciencia en pacientes en estados derivados del coma son actualmente escasas y limitadas, lo que conlleva a un desconocimiento por parte de los médicos y de la familia del paciente acerca de su estado cognitivo. Por esto se busca implementar una interfaz BCI que, mediante el registro de la actividad bioeléctrica cerebral, posibilite una interacción con el cerebro de los pacientes con el objetivo de inferir el estado cognitivo de éstos.

1.2. OBJETIVOS DEL PROYECTO

1.2.1. OBJETIVO GENERAL

Desarrollar un modelo que permita inferir la presencia de conciencia en pacientes en estado comatoso a partir del registro de la actividad bioeléctrica cerebral y mediante la utilización de los principios de la inteligencia computacional.

1.2.2. OBJETIVOS ESPECÍFICOS

- ✓ Caracterizar los patrones de activación que muestran la presencia de conciencia, que servirán para evaluar el estado cognitivo a través de señales electroencefalográficas, a partir de una BCI comercial.
- ✓ Diseñar el modelo que permita clasificar los patrones de activación cerebral mediante la utilización de los principios de la inteligencia computacional.
- ✓ Desarrollar el modelo propuesto mediante la programación orientada a objetos y las tecnologías .NET.
- ✓ Seleccionar el método más apropiado para evaluar a los pacientes en estado comatoso para proceder a inferir el estado de conciencia de los mismos.
- ✓ Validar el modelo propuesto a partir de la asociación que el modelo realiza sobre los patrones de activación electroencefalográfica (EEG) sobre una persona en estado de inconsciencia respecto a una persona sana.

1.3. MARCO TEÓRICO

La conciencia puede ser definida médicamente como la capacidad que tenemos de responder ante algún estímulo, ya sea auditivo, visual, sonoro, entre otros, y por consiguiente de interactuar con el entorno, esto desde una perspectiva de conocimiento. La evaluación del estado cognitivo en pacientes comatosos se realiza mediante diferentes signos clínicos que indican la actividad cerebral y que posteriormente son tratados con el fin de ver si efectivamente el paciente responde ante un estímulo. Esta actividad cerebral puede ser recolectada mediante diferentes herramientas; sin embargo, está sujeta a un margen de error elevado debido a diferentes circunstancias, tales como: “la capacidad de dar respuestas en personas con alteraciones del estado de conciencia es fluctuante y muchas veces su estado de mayor conexión con el entorno no coincide con el momento de la evaluación profesional, la dificultad en la diferenciación de movimientos voluntarios de movimientos reflejos e involuntarios, la influencia de déficits coexistentes: sensitivos, motores y cognitivos que le impiden dar a la persona una respuesta adecuada, cuando se le solicita, por la presencia de éstos.” (Dr Lisandro E. Olmos, 2012).

Unas de las herramientas para detectar la actividad cerebral pueden basarse en el flujo sanguíneo, como lo es por ejemplo la imagen por resonancia magnética funcional (fMRI) o también mediante señales bioeléctricas, como se hace en la electroencefalografía (EEG). Ambas herramientas son ampliamente aplicadas en el campo de la medicina, pero requieren de un tratamiento posterior para realizar un diagnóstico. Para tal fin, existen diversas áreas para captar la actividad cerebral, tales como el cuero cabelludo, la base del cráneo, la superficie del cerebro y el interior del mismo. Esta actividad cerebral es registrada por medio de electrodos, los cuales se encargan de recibir las corrientes eléctricas que más tarde pasan a ser tratadas. Según el área de la cual se capta la señal se nombran los tipos de electrodos, tales como: los electrodos superficiales (sobre el cuero cabelludo), los electrodos basales (sobre el cráneo) y los electrodos quirúrgicos (corticales o intracerebrales). Dentro de los electrodos superficiales están: los electrodos adheridos, que se fijan con colodión y una pasta conductora; los electrodos de contacto, que son tubos de plata clorada que requieren humectación; los electrodos de malla, que se sujetan con cintas y son más cómodos, y por último los electrodos de aguja, los cuales no son tan comunes y no son reutilizables. (Navarro, 2010)

Existen diferentes sistemas de distribución para los electrodos en el cerebro: Illinois, Montreal, Aird, Cohn, Lennox, Merlis, Oastaut, Schwab, Marshall, pero el más común es el sistema internacional “Diez-Veinte” en donde se indican las zonas de actividad cerebral mediante sufijos: P (parietal), O (occipital), F (frontal), T (temporal), etc. En la figura 1 se muestra la distribución de éste sistema:




Figura 1. Sistema de posicionamiento de electrodos "Diez-Veinte" (Navarro, 2010).

Cuando las células del cerebro establecen una comunicación, se producen señales eléctricas de baja amplitud. La captación del registro de los electrodos de superficie o basales se conoce como electroencefalograma (EEG), para los electrodos quirúrgicos corticales se conoce como electrocorticograma (ECoG) y para los electrodos quirúrgicos intracerebrales se conoce como estéreo electroencefalograma (E-EEG). Es de aclarar que mientras más interno se encuentre el electrodo, de mejor calidad son los registros obtenidos. "Para proceder a registrar el EEG se parte de una serie de electrodos situados sobre la superficie del cuero cabelludo en localizaciones precisas, determinadas según el sistema internacional diez - veinte. Cada electrodo es un punto de registro. Sin embargo, para poder realizar este registro es preciso disponer de dos terminales. Por esto habrá que seleccionar cuáles de los electrodos deben ser la fuente de señal registrada en el electroencefalógrafo (instrumento de medida de los impulsos cerebrales), dependiendo del número de canales disponibles y del propósito específico del registro a realizar. En este aspecto, la primera decisión que se deberá tomar será el seleccionar entre Registros Monopolares y Registros Bipolares." (Navarro, 2010). Los registros monopoles tratan cada señal de los electrodos de forma independiente, en donde existe un electrodo activo, que es el electrodo a tratar, y uno de referencia. Los registros bipolares, a diferencia, toman de a parejas y registran su diferencial de tensión.

La conexión entre el cerebro y una computadora se logra a través de una BCI, la cual permite llevar a cabo diferentes tareas que son programadas haciendo uso de la actividad cerebral, en una infinidad de campos tales como la medicina, domótica, robótica, entre otros. Esta interfaz requiere de una retroalimentación de las señales bioeléctricas cerebrales para poder traducirlas y manipularlas. El análisis de los registros obtenidos por las BCI se puede llevar a cabo mediante la aplicación de redes neuronales artificiales. "Una red neuronal es un algoritmo de cálculo que se basa en una analogía del sistema nervioso. La idea general consiste en emular la capacidad de aprendizaje del sistema nervioso, de

manera que la red neuronal aprenda a identificar un patrón de asociación entre los valores de un conjunto de variables predictoras (entradas) y los estados que se consideran dependientes de dichos valores (salidas)” (Nacional, ¿Qué son las redes neuronales artificiales?, 2013). Estas redes neuronales artificiales pueden llegar a identificar de una forma más precisa los estados emocionales, pensamientos y expresiones faciales, que posibilitan un mejor trabajo, considerando la cantidad de factores que intervienen en las pruebas.

La forma en que adquirimos conocimiento y aprendemos ocurre dentro del cerebro, allí las redes neuronales se encargan de crear enlaces entre las neuronas que producen una señal de salida frente a una excitación o entrada. En el proceso de aprendizaje inicialmente no se obtiene la salida deseada u objetivo establecido sino después de varias iteraciones. Por ejemplo, cuando un infante quiere aprender a montar bicicleta, es seguro que en el primer intento no lo logrará, o por lo menos no de la mejor manera, pero después de varios intentos sabrá controlar las variables como el equilibrio y la velocidad que le permitirán manejarla fácilmente. Es de esta forma como las neuronas interactúan entre sí y van construyendo enlaces que permiten el aprendizaje.

1.3.1. FUNCIÓN CEREBRAL EN DIFERENTES DESORDENES CEREBRALES

Una valoración precisa y confiable de la excitación y del estado de alerta de la conciencia en pacientes con un severo daño cerebral, es de gran importancia para el manejo de éstos. Progresos en las unidades de cuidados intensivos han llevado a un incremento en el número de pacientes que sobreviven a un daño agudo y severo. Aunque la mayoría de estos pacientes se recuperan del coma dentro de los primeros días después de la lesión, algunos pierden permanentemente todas las funciones del tronco cerebral (muerte cerebral), mientras que otros progresan al estado de “inconsciencia vigil” (estado vegetativo). Aquellos que se recuperan, típicamente progresan a través de diferentes etapas antes de recuperar completa o parcialmente la conciencia (estado de mínima conciencia; figura 2).¹

¹ La teoría expresada en este capítulo del trabajo fue tomada del artículo: “*Brain function in coma, vegetative state, and related disorders*”, de Steven Laureys, Adrian M Owen y Nicholas D Schiff (Steven Laureys, 2004).

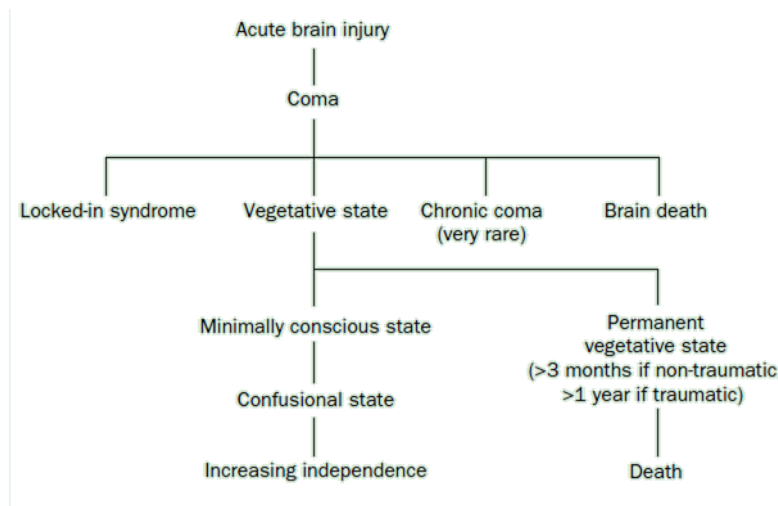


Figura 2. Diagrama de flujo de la lesión cerebral y el coma. El estado vegetativo sigue típicamente luego del coma; después de un mes se usa el término de “estado vegetativo persistente”; luego de tres meses para una lesión no traumática o un año para una lesión traumática algunos autores usan el término de “estado vegetativo permanente”, el cual implica que no existen probabilidades de recuperación (Steven Laureys, 2004).

La práctica clínica ha evidenciado los retos de identificar la percepción consciente de estos pacientes del entorno y de ellos mismos. Son comunes los diagnósticos erróneos de los siguientes estados: vegetativo, de mínima conciencia, y del síndrome de enclaustramiento. En adición, la conciencia no es un fenómeno de todo o nada y sus valoraciones clínicas se centran en inferencias basadas en la observación de repuestas a estímulos externos durante la examinación.




Figura 3. Excitación y estado de alerta, los dos componentes de la conciencia en el coma, estado vegetativo, estado de mínima conciencia y síndrome de enclaustramiento (Steven Laureys, 2004).

1.3.1.1. LA CONCIENCIA, EL ESTADO DE ALERTA Y LA EXCITACIÓN

La conciencia es un concepto multifacético que puede ser dividido en dos componentes principales: excitación (estar despierto o vigilante) y estado de alerta (conocimiento del entorno y de sí mismo) (figura 3). La excitación está soportada por varias poblaciones de neuronas del tronco cerebral que proyectan directamente a las neuronas talámicas y corticales. Por lo tanto, el decaimiento del tronco cerebral o de ambos hemisferios cerebrales puede causar reducción de la vigilia. Los reflejos son importantes en la valoración de la integridad funcional del tronco cerebral. Sin embargo, un deterioro grave de los reflejos del tronco cerebral puede coexistir con funciones intactas del sistema reticular de activación. Se cree que la conciencia depende de la integridad funcional de la corteza cerebral y sus conexiones subcorticales; todas sus partes están localizadas, hasta cierto punto, en regiones del cerebro definidas anatómicamente. Desafortunadamente, la conciencia no puede ser medida objetivamente por cualquier tipo de máquina. Su estimación requiere de la interpretación de varias señales clínicas. Es importante resaltar que muchos sistemas de puntuación ya han sido desarrollados para la cuantificación y estandarización de la valoración de la conciencia.

1.3.1.2. DEFINICIONES CLÍNICAS

Muerte cerebral

El concepto de muerte cerebral como la muerte del individuo es ampliamente aceptado. La mayoría de los países han publicado recomendaciones para el diagnóstico de la muerte cerebral pero el criterio de diagnóstico difiere de país a país. Algunos se fían únicamente en la muerte del tronco cerebral, mientras que otros requieren la muerte de todo el cerebro incluido el tronco cerebral. Sin embargo, las valoraciones clínicas para la muerte cerebral son las mismas y requieren de la pérdida de todos los reflejos del tronco cerebral y de la demostración de apnea continua en un paciente en estado de coma persistente.

Coma

Caracterizado por la ausencia de excitación y por consiguiente de la conciencia, el coma es un estado de falta de repuesta en el que el paciente se encuentra con los ojos cerrados y no puede ser despertado. La estimulación no puede producir períodos espontáneos de vigilia y de apertura de ojos en pacientes en coma, diferente a los pacientes en estado vegetativo. Para ser claramente distinguido de un síncope, una concusión, u otros estados transitorios de inconsciencia, el coma debe persistir por al menos una hora. En general, los pacientes en estado de coma que sobreviven comienzan a despertarse y a recuperarse gradualmente dentro de dos o cuatro semanas. Esta recuperación puede que no progrese más allá de un estado vegetativo o de un estado de mínima conciencia, o puede haber breves o prolongadas etapas antes de una recuperación más completa de la conciencia.

Estado vegetativo

Pacientes en estado vegetativo están despiertos pero son inconscientes de ellos mismos o de su entorno. Jennett y Plum citaron el diccionario de inglés de Oxford para explicar su elección del término “vegetativo”; vegetar es “vivir meramente una vida física carente de

actividad intelectual o relaciones sociales” y vegetativo describe “un cuerpo orgánico capaz de crecer y desarrollarse pero carente de sensación o pensamiento”. “El estado vegetativo persistente” ha sido definido como un estado vegetativo que se mantiene un mes después del daño cerebral traumático o no traumático. Esto no implica irreversibilidad. “El estado vegetativo permanente” es irreversible. El diagnóstico del estado vegetativo debería ser cuestionado cuando hay algún grado de búsqueda visual sostenida, fijación visual consistente y reproducible, o respuesta a gestos amenazantes; teniendo en cuenta que estas respuestas aún son observadas en algunos pacientes que permanecen en el estado vegetativo por años. Es esencial establecer la ausencia formal de cualquier signo de percepción consciente o acción deliberada antes de hacer el diagnóstico.

Estado de mínima conciencia

El grupo Aspen propuso los criterios para el estado de mínima conciencia para categorizar pacientes que no están en un estado vegetativo pero que son incapaces de comunicarse consistentemente. Para estar mínimamente consciente, los pacientes deben mostrar limitada pero clara evidencia de conciencia de ellos mismos o de su entorno, sobre una base reproducible o sostenida, por al menos uno de los siguientes comportamientos: seguir comandos simples, respuesta gestual o verbal si/no (independientemente de la precisión), habla inteligible, comportamiento intencional (incluidos movimientos o comportamientos afectivos que tomen lugar en relación a estímulos en el ambiente y que no se deben a actividad reflexiva). La salida del estado de mínima conciencia está definida por la habilidad de comunicarse o usar objetos funcionalmente. Una mejora adicional es más probable que en pacientes en estado vegetativo. Sin embargo, algunas personas se mantienen en un estado de mínima conciencia permanentemente.

Síndrome de enclaustramiento

El término “síndrome de enclaustramiento” fue introducido por Plum y Posner para describir la cuadriplejía y la anartria como resultado de la interrupción o ruptura de las vías corticoespinal y corticobulbar, respectivamente. El síndrome de enclaustramiento está definido por la apertura sostenida de los ojos, conciencia del entorno, afonía o hipofonía, cuadriplejía o cuadriparesia, y movimiento vertical o lateral del ojo o parpadeo del párpado superior como señal para respuestas si/no. Movimientos del ojo o del párpado son el método principal de comunicación.

1.3.1.3. ASPECTOS METODOLÓGICOS

Técnicas como H₂O – PET, fMRI y los estudios de activación MEG pueden ser métodos viables para la valoración del procesamiento cognitivo o poblaciones potencialmente reclutables de neuronas en pacientes con un severo daño cerebral. Sin embargo, como en los estudios metabólicos, estas investigaciones son metodológicamente complejas y los resultados son a menudo equívocos. Por ejemplo, en pacientes con daño cerebral la unión de la actividad neuronal y de la hemodinámica local, esencial para todas las medidas de activación de H₂O – PET y fMRI, es probable que sea diferente de aquellos controles sanos, haciendo extremadamente difícil la interpretación de dichos conjuntos de datos. A pesar de esta básica preocupación metodológica la elección del experimento también es crucial. Por ejemplo, si las respuestas del tronco cerebral evocadas auditivamente son anormales, la

estimulación auditiva puede ser inapropiada y se debería considerar una estimulación alternativa, como la estimulación visual. La investigación también debería ser lo suficientemente compleja para que los procesos cognitivos de interés sean estudiados, pero no tan compleja que las tareas pudiesen sobrecargar fácilmente las capacidades cognitivas de un paciente cansado o inatento. En adición, de modo que los datos obtenidos de pacientes puedan ser interpretados, la investigación debe producir patrones de activación bien documentados, anatómicamente específicos, robustos, y reproducibles en voluntarios sanos.

En estado vegetativo, estado de mínima conciencia, y síndrome de enclaustramiento, son comunes episodios de baja excitación y sueño, y es esencial un monitoreo cercano del paciente (preferiblemente mediante grabaciones de EEG) durante los escaneos de activación de tal forma que esos periodos puedan ser evadidos. Movimientos espontáneos durante el mismo escaneo pueden comprometer la interpretación de los datos de neuroimágenes funcionales, particularmente con escaneos de fMRI. El procesamiento de estos datos también puede presentar problemas difíciles en pacientes con un agudo daño cerebral. Bajo estas circunstancias, la valoración estadística de los patrones de activación y la interpretación de los focos de activación puede ser imposible. Finalmente, como para todos los estudios PET en seres humanos, cuestiones de exposición a la radiación deben ser consideradas y pueden imposibilitar estudios longitudinales o de seguimiento en estos pacientes.

En resumen, estos estudios PET, fMRI o incluso con EEG proveen nuevas oportunidades en la valoración de pacientes con un grave daño cerebral. Sin embargo, todas estas técnicas son metodológicamente complejas con muchos problemas de análisis e interpretación.

1.3.2. ARTEFACTOS BIOLÓGICOS

Los artefactos biológicos o artefactos fisiológicos son actividades eléctricas causadas por el paciente, pero no generadas por el cerebro mismo.

Como se puede evidenciar en la tabla 1 los artefactos tienden a tener una mayor amplitud en comparación con la señal EEG. Desafortunadamente los rangos de frecuencia también se superponen en cierta medida. Siendo un componente significativo de la señal obtenida, es crucial tomar en cuenta los artefactos para los análisis.²

² Capítulo tomado de la tesis *“EEG Signal Processing and Emotiv’s Neuro Headset”* de *Bernt Schiele y Ralf Biedert* (Bernt Schiele, 2010).

Señal	Rango de amplitud		Rango de frecuencia (Hz)	
	Desde	Hasta	Desde	Hasta
EEG	2 μ V	100 μ V	0.5	100
EEG (EP)	0.1 μ V	20 μ V	1	3000
EOG (electrooculograma)	10 μ V	5 mV	0	100
EMG (electromiografía)	50 μ V	5 mV	2	500
ECG (electrocardiograma)	1 mV	10 mV	0.05	100

Tabla 1. Rangos de amplitud y frecuencia de algunos artefactos biológicos. Es importante resaltar que estos datos fueron tomados lo más cerca posible del origen de la actividad eléctrica (Bernt Schiele, 2010).

1.3.3. POTENCIALES RELACIONADOS CON EVENTOS (ERP)

Los potenciales relacionados con eventos (ERP, por sus siglas en inglés) son pequeños cambios en la actividad eléctrica cerebral grabada con un EEG y provocados por eventos internos (tareas cognitivas) o externos (estímulos).

Los cambios de potencial positivo o negativo son comúnmente etiquetados con “P” (positivo) o “N” (negativo), y el número del tiempo correspondiente a la aparición del evento. Consecuentemente, N400 representa un pico negativo 400 ms después del evento.²

1.3.4. P300

El P300, es un ERP positivo que ocurre 300 ms después de un evento en el que se le ha indicado al paciente que genere algún tipo de respuesta. El P300 consiste de dos componentes que se superponen: P3a el cual está relacionado con novedad, que es un evento acerca del cual el sujeto no ha sido instruido como un sonido o imagen inusuales, y el P3b el cual es provocado luego de evento relacionado con tareas.²

Los componentes del P300 pueden ser distinguidos por su localización y latencia (figura 4).




Figura 4. Señal y localización de la medida de P3a y P3b (Bernt Schiele, 2010).

1.3.5. BANDAS DE FRECUENCIA

Las ondas cerebrales oscilan con una frecuencia de 0,5 Hz a 100 Hz, que es directamente proporcional al grado de actividad cerebral. Estas ondas se clasifican en: ondas alfa, que se registran en personas despiertas y sin actividad; ondas beta, que se registran en estado de tensión; ondas teta, que se presentan en presencia de estrés emocional y las ondas delta, que se muestran durante el sueño.

Las bandas de frecuencia son los rangos en los que se encuentran cada una de las ondas cerebrales que indican la actividad eléctrica cerebral, la cual permite inferir el tipo de actividad mental que está ejecutando cierto sujeto. En la tabla 2 se muestran las bandas de frecuencia para cada onda cerebral.²

Frecuencia (Hz)	Onda cerebral
0 – 4	Delta
4 – 8	Theta
8 – 12	Alpha
12 – 30	Beta
30 - 80	Gama

Tabla 2. Rango de frecuencia de las ondas cerebrales (Bernt Schiele, 2010).

1.3.6. EMOTIV EPOC HEADSET

Esta BCI desarrollada por Emotiv Systems está equipada con 14 sensores o electrodos salinos y dos sensores adicionales que sirven como canales de referencia para realizar electroencefalografía. Antes de ser usado, todas las almohadillas que van sobre los sensores se deben hidratar con una solución salina. Finalmente, se debe verificar la calidad de la conexión para cada sensor.

Internamente el Epoc tiene una frecuencia de muestreo de 2048 Hz, la cual es reducida a 128 Hz. Luego se llevan a cabo los siguientes pasos de pre procesamiento en el hardware:

- ✓ Filtro pasa bajo con un corte en 85 Hz.
- ✓ Filtro pasa alto con un corte en 0.16 Hz.
- ✓ Filtro elimina banda (filtro notch) entre 50 Hz y 60Hz.

En tabla 3 se presentan las especificaciones del Emotiv EPOC, que es información necesaria para el empleo y post tratamiento de los datos obtenidos del mismo.³

³ Capítulo tomado de la sitio web oficial de *Emotiv Systems* (Emotiv, 2013).

Número de Canales	14 (más 2 de referencia)
Nombre de los Canales (Localización: Int. 10-20)	AF3, AF4, F3, F4, F7, F8, FC5, FC6, P3, P4, P7, P8, T7, T8, O1, O2
Método de Muestreo	Muestreo Secuencial, Solamente ADC
Frecuencia de Muestreo	~128Hz (2048Hz internos)
Resolución	16 bits (14 bits efectivos) 1 LSB = 0.51 μ V
Ancho de Banda	0.2 - 45Hz, filtros digitales de corte (50Hz y 60Hz)
Rango Dinámico	256mVpp
Modo de Acoplamiento	Acoplamiento AC
Conectividad	Wireless, Banda de 2.4GHz
Tipo de Batería	Litio-polímero
Duración de la Batería	12 h
Medición de Impedancia	Por Contactos
Electrodos de Referencia	P4 (CMS) y P5 (DRL)

Tabla 3. Especificaciones técnicas del Emotiv Epoc (Emotiv, 2013).

La localización de los electrodos en el Emotiv emplea el sistema internacional 10-20, que se muestra en la figura 5:




Figura 5. Distribución 10-20 empleada para los electrodos del Emotiv Epoc (Emotiv, 2013).

1.3.7. PROCESAMIENTO DE LOS DATOS

La serie de pasos para obtener el registro de datos de la actividad bioeléctrica cerebral y llevar a cabo el procesamiento de los datos se presenta a continuación.

1.3.7.1. ADQUISICIÓN DEL RAW DATA

Mediante la aplicación del Emotiv llamada TestBench se pueden guardar y cargar registros de la actividad bioeléctrica cerebral (RAW DATA) durante un periodo de tiempo determinado por el usuario. El formato que se maneja para estos registros es EDF, pero también posee un conversor de EDF a CSV (que es un formato importable en Excel).

Los datos que se exportan en este formato son los siguientes:

- ✓ Título del registro de datos.
- ✓ Fecha y hora de la grabación.
- ✓ Sujeto de prueba.
- ✓ Vector contador de muestras.
- ✓ Vector booleano que indica si se realizó una interpolación para corregir algún dato o serie de datos.
- ✓ Matriz 14xND con los registros en μV de los diferentes electrodos.
- ✓ Vector RAW_CQ que indica la medida de conductividad derivada de la calidad de los contactos en el momento.
- ✓ Matriz 14*ND con CQ indicando la conductividad particular de cada electrodo en todos los instantes.
- ✓ Dos vectores GYROX y GYROY que miden la diferencia horizontal y vertical en la lectura teniendo en cuenta la medición anterior.
- ✓ Vector que indica si se adiciono un marcador en una muestra específica.

ND: Número de Datos

Los datos más relevantes que se deben extraer son los registros en μV de los diferentes electrodos y el contador de muestras, obviamente teniendo en cuenta que el estado de conductividad de todos los electrodos hubiese sido el óptimo. A continuación se presenta un ejemplo de los datos relevantes extraídos de una prueba:

Electrodos (14)

	K	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
Número de Muestra	1	4372.3	4373.3	4189.2	3943.6	4327.7	4698.5	4380.0	4290.3	4205.6	4275.9	4419.0	4446.2	3731.8	4388.2
	2	4362.6	4368.7	4182.6	3938.5	4324.6	4697.4	4380.0	4293.8	4204.6	4279.5	4412.8	4439.5	3727.2	4380.5

	ND	4374.4	4381.0	4200.0	3942.1	4326.2	4696.4	4380.5	4281.5	4199.0	4294.9	4415.4	4440.5	3736.9	4380.0

Registro de Actividad Bioeléctrica Cerebral (μV)

Tabla 4. Ejemplo de los datos relevantes del RAW DATA.

Si graficásemos un electrodo (AF3) contra el contador de muestras, tendríamos (figura 6):




Figura 6. Señal eléctrica del electrodo AF3.

1.3.7.2. PREPROCESAMIENTO DE LOS DATOS

Una vez obtenidos los registros puros de la actividad bioeléctrica cerebral, se procede a realizar una serie de filtros digitales para eliminar problemas asociados con el ruido de la señal, los artefactos (movimientos involuntarios, parpadeo, etc.), el offset, entre otros, que ocasionan o impiden la correcta visualización y tratamiento de los registros electroencefalográficos. A continuación se presentan algunos de los filtros digitales que más se aplican en las señales extraídas del Emotiv.

1.3.7.2.1. FILTRO PASA BAJO Y PASA ALTO

Estos filtros permiten el paso de un determinado rango de frecuencias de la señal y atenúan el resto. Se recomienda hacer un filtro pasa alto de 1 Hz para atenuar un poco el ruido de baja frecuencia y un filtro pasa bajo de 50 Hz.⁴

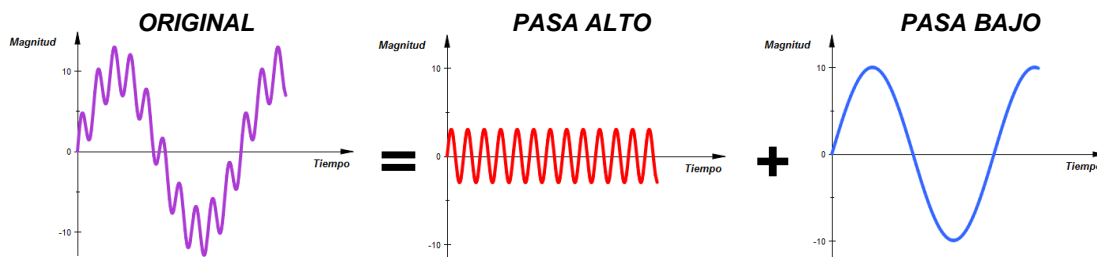


Figura 7. Filtros pasa bajo y pasa alto.

⁴ Capítulo tomado del sitio web oficial del Centro para la Neurociencia Computacional Swartz (Neuroscience, 2013).

1.3.7.2.2. REMOCIÓN DE LA LÍNEA BASE

Este proceso se usa para eliminar tendencias ascendentes o descendentes sobre las cuales la señal de interés está montada. Para llevarlo a cabo este, se busca una función de la línea base que puede ser polinomial; luego de conocida ésta se procede a reorientar la señal eliminando la región base.⁴




Figura 8. Línea de base.

1.3.7.2.3. ANÁLISIS DE COMPONENTES INDEPENDIENTES (ICA)

El análisis de componentes independientes (ICA, por sus siglas en inglés) es un método que ha sido desarrollado para el tratamiento de las señales EEG. Éste genera filtros espaciales que permiten un monitoreo separado de la actividad cerebral en diferentes áreas corticales. La mayor ventaja de este método es que la actividad que constituye una simple fuente EEG es agrupada en componentes independientes simples (IC) que incluyen sus proyecciones a todos los canales, mientras que las actividades de fuentes EEG no relacionadas se rechazan. De esta manera, el ICA transforma los datos puros en un conjunto de señales corticales y señales de artefactos.

El ICA produce, aplicado a los datos EEG, una descomposición lineal e invertible de los datos, significando que la actividad resultante de cada componente independiente (IC) es simplemente la suma ponderada de las señales grabadas de todos los canales de entrada, y la señal de cada canal es simplemente la suma ponderada de las actividades proyectadas de todos los componentes independientes (ICs). Técnicamente el ICA encuentra un conjunto de filtros espaciales fijos, que constituyen las señales más claras disponibles en los datos de entrada.⁵

En la figura 9 se muestra un ejemplo del análisis de componentes independientes aplicado a una serie de 22 electrodos y una posterior corrección de los componentes artefactuales identificados.

⁵ Capítulo tomado del artículo "Extended ICA Removes Artifacts from Electroencephalographic Recordings" de Tzyy-Ping Jung et Al (Tzyy-Ping Jungl, 1998).

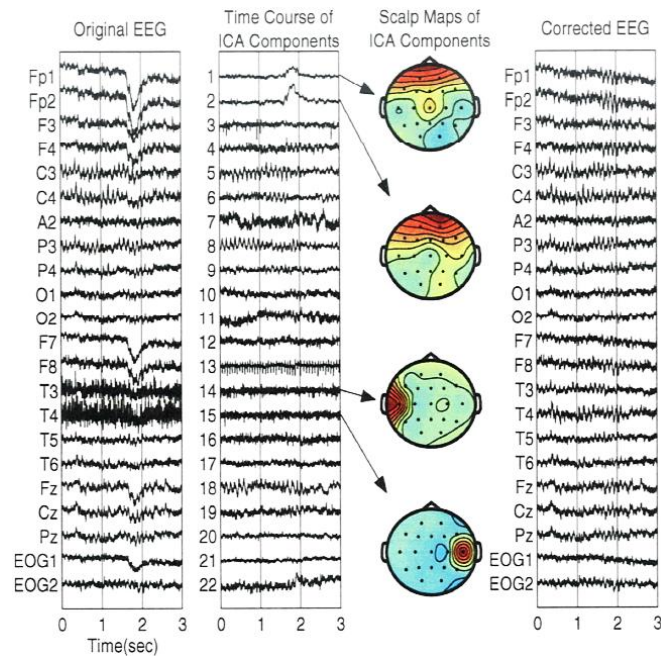


Figura 9. Análisis de Componentes Independientes (Tzyy-Ping Jung, 1998).

En la figura 10 se muestra al detalle el ejemplo de un componente independiente catalogado como un artefacto de ojos, el cual se debe remover.

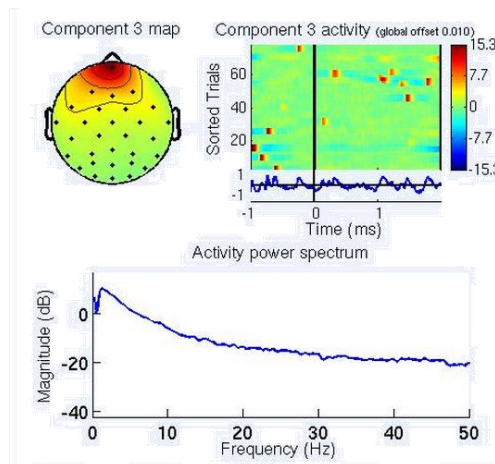


Figura 10. Artefacto de ojos. El mapa auto-organizado de la actividad cerebral mostrado en la esquina superior izquierda es un típico ejemplo de un artefacto ocasionado por un parpadeo. El grafo de la esquina superior derecha muestra la actividad cerebral desde 1ms antes de ocurrido el evento hasta 2 ms después. En la parte inferior se muestra el espectro de potencia para el artefacto en cuestión. (Neuroscience, 2013).

1.3.7.3. TRANSFORMADA DE FOURIER

La transformada de Fourier es una transformada matemática que permite determinar el espectro de frecuencias de una determinada función; ésta relaciona una función en el dominio del tiempo con una función en el dominio de la frecuencia, y está definida por la ecuación 1:

$$\hat{f}(\xi) = \int_{-\infty}^{\infty} f(x) e^{-2\pi i \xi x} dx \quad (1)$$

Para el análisis de registros electroencefalográficos, se implementa la transformada de Fourier para posteriormente analizar el espectro de potencias, el cual es el que finalmente indica el comportamiento de cada banda de frecuencia.⁶

1.3.7.4. PERIODOGRAMA

El periodograma es un estimado no paramétrico de la densidad espectral de potencia (PSD, por sus siglas en inglés) de un proceso aleatorio estacionario en sentido amplio; es la transformada de Fourier de la estimación parcial de la secuencia de autocorrelación. Para una señal x_n , muestreada a una frecuencia f_s , el periodograma está definido por la ecuación 2 como:

$$\hat{P}(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} x_n e^{-i2\pi f n} \right|^2 \quad \frac{-1}{2\Delta t} < f \leq \frac{1}{2\Delta t} \quad (2)$$

Donde Δt es el intervalo de muestreo. Para un periodograma unilateral, los valores de todas las frecuencias excepto 0 y la de Nyquist, $1/2\Delta t$, son multiplicadas por 2 de manera que la potencia total sea conservada.⁷

Si las frecuencias están en radianes/muestra, el periodograma está definido por la ecuación 3 como:

$$\hat{P}(f) = \frac{1}{2\pi N} \left| \sum_{n=0}^{N-1} x_n e^{-i\omega n} \right|^2 \quad -\pi < \omega \leq \pi \quad (3)$$

1.3.7.5. PERIODOGRAMA MODIFICADO⁷

El periodograma modificado aplica una función de ventaneo a las series de tiempo de entrada, con el objetivo de solucionar el problema de enmascaramiento espectral.

Si h_n es una función de ventaneo, el periodograma modificado está definido por la ecuación 4 como:

$$\hat{P}(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} h_n x_n e^{-i2\pi f n} \right|^2 \quad \frac{-1}{2\Delta t} < f \leq \frac{1}{2\Delta t} \quad (4)$$

⁶ Capítulo tomado del libro: “*Applications of Fourier Transforms to Generalized Functions*” de M. Rahman.

⁷ Capítulo tomado del sitio web oficial de Mathworks (Mathworks, 2013).

Donde Δt es el intervalo de muestreo. Si las frecuencias están en radianes/muestra, el periodograma está definido por la ecuación 5 como:

$$\hat{P}(f) = \frac{1}{2\pi N} \left| \sum_{n=0}^{N-1} h_n x_n e^{-i\omega n} \right|^2 \quad -\pi < \omega \leq \pi \quad (5)$$

1.3.8. REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales son paradigmas de programación y aprendizaje para el procesamiento automático de datos e información, basados en la forma funcional de los cerebros biológicos. Emulando el funcionamiento del cerebro en un nivel primitivo, se logran crear sistemas altamente paralelos los cuales están formados por un vasto número de procesos simples que se encuentran interconectados.

Estas redes neuronales, normalmente organizadas en capas, están formadas por un número determinado de neuronas unidas por conexiones unidireccionales con un peso asociado, de manera que el procesamiento de la información llevado a cabo por cada neurona depende únicamente de los pesos, las entradas, y en ocasiones, del estado anterior de la neurona.

La salida emitida por cada neurona está dada por la acción conjunta de tres funciones: una función de propagación, una función de activación y una función de transferencia.⁸

1.3.8.1. REDES NEURONALES CON CONEXIÓN HACIA ADELANTE (PROCESO FEEDFORWARD)

Las redes neuronales que emplean el proceso feedforward o con conexión hacia adelante se caracterizan porque su organización es en capas, sus conexiones son estrictamente hacia adelante y usan algoritmos para realizar entrenamiento supervisado. Dentro de las redes con conexión hacia adelante se encuentran el perceptrón multicapa y las redes de base radial.

1.3.8.1.1. PERCEPTRÓN MULTICAPA

El perceptrón multicapa es una red que está compuesta de varias capas de neuronas entre la entrada y la salida, que emplea el proceso feedforward (proceso en el que las salidas de las neuronas van a las siguientes capas pero no a las anteriores), y que permite la resolución de problemas no lineales mediante la aproximación de la relación entre los datos de entrada y salida.

⁸ Capítulo tomado de los libros “*Neural Networks: A Systematic Introduction*” de Raúl Rojas (Rojas R. , 1996) y “*Redes de Neuronas Artificiales – Un Enfoque Práctico*” de Pedro Isasi e Inés Galván (Pedro Isasi Viñuela, 2004).

El perceptrón multicapa está compuesto por:

- ✓ Capa de entrada: se encarga de recibir las señales de entrada y propagarlas a la siguiente capa.
- ✓ Capa de salida: proporciona la respuesta de la red para cada patrón de entrada.
- ✓ Capa oculta: realiza un procesamiento no lineal de los datos de entrada.

En la figura 11 se presenta la configuración del perceptrón multicapa.




Figura 11. Arquitectura del perceptrón multicapa (Pedro Isasi Viñuela, 2004).

La propagación de los patrones de entrada define una relación entre las variables de entrada y salida de la red. Esta relación se obtiene principalmente mediante el proceso feedforward. Cada neurona de la red procesa la información recibida por sus entradas y produce una respuesta (activación) que se propaga a las neuronas de la siguiente capa, a través de las conexiones correspondientes.

1.3.8.1.1.1. APRENDIZAJE EN EL PERCEPTRÓN MULTICAPA

A continuación se presenta el procedimiento que se debe llevar a cabo para el proceso de aprendizaje del perceptrón.

1. Se inicializan los pesos y umbrales.
2. Se ingresa un patrón de entrenamiento "n" y se propaga hacia la salida, obteniendo la salida de la red "y(n)".

3. Se valúa el error cuadrático “e(n)”.
4. Se aplica la Regla Delta Generalizada para modificar los pesos y umbrales:
 - ✓ Se calculan los valores delta para todas las neuronas de la capa de salida.
 - ✓ Se calcula delta para el resto de neuronas, empezando por la última capa oculta y terminando en la capa de entrada.
 - ✓ Se modifican los pesos y umbrales.
5. Se repiten los pasos 2, 3 y 4 para todo el patrón de entrenamiento.
6. Se evalúa el error total de la red.
7. Se repite el procedimiento hasta alcanzar el criterio de parada especificado.

1.3.8.1.2. RED NEURONAL DE BASE RADIAL

Las redes neuronales de base radial son redes multicapa con conexiones feedforward y que sólo poseen una capa oculta; además son aproximadores universales, en el sentido que mediante la definición de esferas o elipses para dividir el espacio de entrada, construyen aproximaciones que son combinaciones lineales de múltiples funciones locales no lineales. Estas redes calculan la salida en función de la distancia que hay a un punto denominado centro. Cada neurona de la red está compuesta por:

- ✓ Capa de entrada: se encarga de transmitir las señales sin realizar procesamiento alguno, debido a que las conexiones no tienen pesos asociados.
- ✓ Capa oculta: se encarga de realizar una transformación local y no lineal de las señales.
- ✓ Capa de salida: se encarga de realizar una combinación lineal de las activaciones de la capa oculta.

Las redes de base radial emplean una función, conocida como función de base radial, para calcular la distancia euclídea de un vector de entrada X respecto a un centro C , como se muestra en la ecuación 7:

$$f(x) = (\|x - c_i\|) \quad (7)$$

A cada neurona de la capa de entrada le corresponde una de estas funciones y un peso determinado, dando como resultado la función de la red de base radial presentada en la ecuación 8:

$$F(x) = \sum_{i=1}^N w_i \phi(\|x - c_i\|) \quad (8)$$

En la figura 12 se presenta la arquitectura de las redes neuronales de base radial.




Figura 12. Arquitectura de las redes neuronales de base radial (Pedro Isasi Viñuela, 2004).

1.3.8.1.2.1. APRENDIZAJE EN LA RED DE BASE RADIAL

En las redes neuronales de base radial el aprendizaje consiste en la determinación de los centros, desviaciones y pesos de la capa oculta a la capa de salida. Para optimizar el proceso de aprendizaje y debido a que las capas realizan tareas diferentes, se lleva a cabo la separación de los parámetros de la capa oculta y de la capa de salida, asegurando que los centros y las desviaciones sigan un proceso guiado por la optimización en el espacio de entrada, y los pesos la optimización con base a las salidas deseadas. A continuación se presenta el procedimiento que se debe llevar a cabo para el proceso de aprendizaje de este tipo de redes.

1. Se inicializan todos los parámetros de la red (pesos, umbrales y centros).
2. Se toma un patrón conjunto de patrones disponibles ($x(n)$, $s(n)$) y se calcula la salida de la red " $y(n)$ ", para el patrón de entrada " $x(n)$ ".
3. Se evalúa el error cuadrático " $e(n)$ ".
4. Se modifican los pesos, umbrales, centros y amplitudes de la red.
5. Se repiten los pasos 2, 3 y 4 para todos los patrones de entrenamiento.
6. Se evalúa el error total de la red.
7. Se repite el procedimiento hasta alcanzar el criterio de parada especificado.

1.3.8.1.2.2. FUNCIONES DE ACTIVACIÓN

Para las redes neuronales de base radial existen diferentes funciones de activación:

- ✓ Función Gausiana, definida por la ecuación 9 como:

$$\phi(r) = e^{-(\epsilon r)^2} \quad (9)$$

- ✓ Función Multicuadrática, definida por la ecuación 10 como:

$$\phi(r) = \sqrt{1 + (\epsilon r)^2} \quad (10)$$

- ✓ Función Multicuadrática Inversa, definida por la ecuación 11 como:

$$\phi(r) = \frac{1}{\sqrt{1 + (\epsilon r)^2}} \quad (11)$$

- ✓ Función Spline Poliarmónico, definida por las ecuaciones 12 y 13 como:

$$\phi(r) = r^k, k = 1, 3, 5, \dots \quad (12)$$

$$\phi(r) = r^k \ln(r), k = 2, 4, 6, \dots \quad (13)$$

- ✓ Función Spline de placa delgada, definida por la ecuación 14 como:

$$\phi(r) = r^2 \ln(r) \quad (14)$$

1.3.8.2. REGLA DELTA GENERALIZADA (PROCESO BACKPROPAGATION)

La Regla Delta Generalizada es un algoritmo de aprendizaje supervisado que es utilizado en el proceso de entrenamiento de este tipo de redes neuronales. Este algoritmo permite el trabajo con múltiples capas y con funciones de activación no lineales.

El algoritmo emplea el siguiente procedimiento:

- ✓ Una vez que se ha aplicado un patrón de entrada a la red, éste se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida.
- ✓ La señal de salida es comparada con la salida deseada, calculando así un determinado error para cada salida.
- ✓ El proceso se repite capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total.

1.3.8.3. FUNCIÓN DE SALIDA

El valor resultante de esta función es la salida de la neurona, por ende la función de salida determina el valor que se transfiere como salida, llevando a cabo una transformación del estado actual de activación de una señal.

Existen diferentes tipos de funciones de salida:

- ✓ Función escalón o binaria.
- ✓ Función lineal y mixta.
- ✓ Función sigmoideal.
- ✓ Función gaussiana.

Por ejemplo, si se aplica una función lineal identidad a la salida, esto equivaldría a no aplicar una función de salida.

La función escalón se emplea únicamente cuando se requiere que las salidas de la red sean binarias. Ésta puede ser usada en la clasificación de dos estados o patrones, debido a que permite la asignación de “1” para un determinado rango dentro del umbral y de “0” para el rango restante.

1.3.8.4. CRITERIOS DE PARADA

Existen diferentes tipos de criterios de parada con los cuales se finaliza el periodo de aprendizaje, éstos son:

- ✓ Mediante un número fijo de ciclos.
- ✓ Cuando el error desciende por debajo de una cantidad preestablecida.
- ✓ Cuando la modificación de los pesos sea irrelevante.
- ✓ Cuando el error cambia su tendencia decreciente y comienza a aumentar.

2. PROCEDIMIENTO METODOLÓGICO

Para el desarrollo del proyecto se exponen las siguientes etapas:

Etapas 1. Caracterizar los patrones de entrada que muestran la presencia de conciencia, que servirán para evaluar la activación cerebral a través de señales electroencefalográficas, a partir de una BCI comercial:

- Se investigará en la web acerca de los diferentes tipos de headsets o mindsets que existen en el mercado para obtener los registros de la actividad bioeléctrica cerebral, teniendo en cuenta los estados mentales que es capaz de detectar, así como las expresiones faciales, pensamientos, etc.
- Se analizarán los lenguajes de programación más apropiados para desarrollar el modelo, examinando también las licencias que ofrecen las diferentes compañías teniendo en cuenta la flexibilidad y accesibilidad a los datos obtenidos por la respectiva BCI. Toda esta información se encuentra disponible en los respectivos sitios web oficiales.
- Se revisarán los factores de error que comúnmente suceden con las mediciones que se realizan a los pacientes comatosos para prever posibles errores que se puedan producir al momento de evaluar a los pacientes.
- Se definirán los estímulos más adecuados para hacer la evaluación, de modo que aseguren por lo menos dos patrones de activación cerebral diferentes, es decir dos estados mentales previamente definidos, para detectar la respuesta del paciente de una forma más precisa.

Etapas 2. Diseñar el modelo que permita clasificar los patrones de activación cerebral mediante la utilización de los principios de la inteligencia computacional.

- Se obtendrá registros regulares de la actividad cerebral de pacientes conscientes en estado de relajación y frustración mediante electroencefalografía (EEG) para el posterior proceso de identificación y clasificación de la red neuronal artificial.
- Plantear el modelo para identificar y clasificar los patrones de activación cerebral.

Etapas 3. Desarrollar el modelo propuesto mediante la programación orientada a objetos y las tecnologías .NET.

- Se realizará un modelo que emplee los registros regulares captados de pacientes conscientes de modo que se comparen posteriormente con las respuestas obtenidas en nuevas pruebas para así poder determinar el grado de similitud que conllevan.

Etapas 4. Seleccionar el método más apropiado para evaluar a los pacientes en estado comatoso para proceder a inferir el estado de conciencia de los mismos.

- Se planteará un protocolo de comunicación con el cual se pueda establecer una conexión con el paciente teniendo en cuenta los estadios de activación cerebral para definir una respuesta afirmativa, negativa o la ausencia de conciencia en el mismo.

Etapa 5. Validar el modelo propuesto a partir de la asociación que el modelo realiza sobre los patrones de activación electroencefalográfica EEG con pruebas exentas del proceso de aprendizaje de la red neuronal artificial.

- Evaluar el comportamiento de la red neuronal frente al aprendizaje obtenido con los pacientes de prueba inicial.
- Verificar el comportamiento de la red neuronal frente a los patrones de activación estipulados de modo que se aseguren los dos estadios de activación neuronal.
- Validar el correcto funcionamiento del modelo mediante pruebas que sugieran el grado de conciencia del paciente tratado.


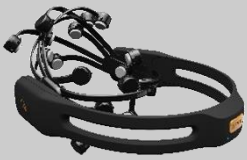


3. DESARROLLO DEL MODELO

En este capítulo se presenta el desarrollo del trabajo siguiendo las pautas planteadas en el procedimiento.

3.1. CARACTERIZAR LOS PATRONES DE ENTRADA QUE MUESTRAN LA PRESENCIA DE CONCIENCIA:

3.1.1. INVESTIGAR LOS DIFERENTES TIPOS DE HEADSETS:

Existen diferentes BCI que miden la actividad bioeléctrica cerebral, en la tabla 5 se presentan los headsets comerciales ideales para la medición de estados emocionales y por ende para la aplicación.

FABRICANTE	REFERENCIA	ESPECIFICACIONES	PRECIO
 Emotiv Systems	EPOC 	Canales: 14 Interpretación de 4 estados mentales Interpretación de pensamientos Interpretación de expresiones o gestos. Sin acceso a la información EEG preprocesada. (RAW DATA)	299USD
 Emotiv Systems	EEG 	Canales: 14 Interpretación de 4 estados mentales. Interpretación de pensamientos. Interpretación de expresiones o gestos. Con acceso a la información EEG preprocesada. (RAW DATA)	750USD

FABRICANTE	REFERENCIA	ESPECIFICACIONES	PRECIO
		<p>Canales: 1</p> <p>Interpretación de 2 estados mentales.</p> <p>Identificación de parpadeo.</p> <p>Sin acceso a la información EEG preprocesada. (RAW DATA)</p>	79.99USD
	<p>MINDSET</p> 	<p>Canales: 1</p> <p>Interpretación de 2 estados mentales.</p> <p>Identificación de parpadeo.</p> <p>Con acceso a la información EEG preprocesada. (RAW DATA)</p>	199.99USD
	<p>ENOBIO</p> 	<p>Canales: 8</p> <p>Interpretación de pensamientos.</p> <p>Interpretación de expresiones o gestos.</p> <p>Con acceso a la información EEG preprocesada. (RAW DATA)</p>	3.995 €

FABRICANTE	REFERENCIA	ESPECIFICACIONES	PRECIO
	ENOBIO 	Canales: 20 Interpretación de pensamientos. Interpretación de expresiones o gestos. Con acceso a la información EEG preprocesada. (RAW DATA)	12.495 €

Tabla 5. Comparación entre headsets comerciales (Imágenes obtenidas de los sitios web oficiales (Emotiv, 2013), (Neurosky, 2013), (Neuroelectrics, 2013)).

Teniendo en cuenta las necesidades de poseer la información EEG preprocesada y la mayor cantidad de electrodos con la mejor resolución posible para obtener una medición más precisa, se logra evidenciar que el headset más apropiado para la aplicación es el Emotiv EEG, el cual aparte de estar dentro de un rango presupuestal aceptable es el headset que la universidad posee para investigación. Es importante aclarar que los dos últimos headsets expuestos de NE (Neuroelectrics®) son los más adecuados técnicamente pero se salen del rango de presupuesto del proyecto.

3.1.2. LENGUAJES DE PROGRAMACIÓN

Para el desarrollo de la aplicación se tuvo en consideración el potencial de reconocimiento de patrones que permite la programación mediante redes neuronales. Con el análisis al que fueron sometidos los lenguajes de programación se buscó determinar cuál era el más apropiado. El análisis se llevó a cabo comparando los siguientes factores:

- ✓ Plataformas de destino.
- ✓ Bibliotecas existentes.
- ✓ Manejo del uso de la memoria.
- ✓ Destrezas o conocimientos en el lenguaje de programación.
- ✓ Nivel del lenguaje de programación.

Los lenguajes de programación evaluados fueron:

- ✓ C.
- ✓ C++.
- ✓ C#.
- ✓ Java.
- ✓ Visual Basic.
- ✓ Visual Basic .NET.

De acuerdo a los factores de decisión expuestos anteriormente se definió que el lenguaje de programación más apropiado es el Visual Basic .NET, por su facilidad de integración con Excel (donde se almacenan las bases de datos de las pruebas), su fácil uso y manejo, y la destreza que se tiene del mismo. Por lo anterior las redes neuronales artificiales a emplear en el desarrollo del modelo serán programadas en este lenguaje. En el anexo 3 y en el anexo 4 se presenta el detalle de las redes neuronales programadas.

Por otra parte se encontró que para el procesamiento de los datos EEG existe un toolbox de MATLAB de gran utilidad llamado EEGLab. Este toolbox permite tratar las señales puras EEG, mediante la aplicación de diferentes filtros, el reconocimiento de eventos, la remoción de artefactos a través del análisis de componentes independientes, entre otros.

3.1.3. FACTORES DE ERROR

Al momento de hacer las pruebas para la adquisición de los datos a tratar y a analizar se pueden presentar diferentes factores de error que pueden comprometer la veracidad de los estudios, tanto en los pacientes de control como en los pacientes en estados derivados del coma.

Para los primeros, estos factores suelen suceder debido a causas fisiológicas que no están relacionadas con un detrimento cognitivo o a causas externas que afectan la concentración; para los pacientes de control se deben tener en cuenta los factores enunciados a continuación:

- ✓ Los artefactos biológicos generados por movimientos oculares, tensiones musculares o palpitaciones, pueden alterar la señal a tratar.
- ✓ Se debe tener en cuenta que tan sólo el estímulo auditivo podría generar una respuesta cerebral.
- ✓ En el momento de la prueba cabe la posibilidad de que el paciente no lleve a cabo adecuadamente la tarea cognitiva o piense en situaciones sin relación a ésta.
- ✓ El paciente podría ser distraído de la tarea cognitiva asignada por alguna causa exterior.

Cuando se trata de pacientes en estados derivados del coma y se pretende realizar un electroencefalograma se deben considerar, además de los factores mencionados anteriormente, las siguientes consideraciones:

- ✓ La capacidad de estas personas para responder frente a un estímulo es fluctuante.
- ✓ Es posible que en el instante de la prueba el paciente no se encuentre consciente, es decir, en un estado de relajación profundo por un periodo de tiempo indeterminado.
- ✓ La dificultad que representa identificar los reflejos voluntarios de los involuntarios en la actividad cerebral del paciente.
- ✓ Presencia de déficits sensitivos, motores y cognitivos que imposibilitan una respuesta adecuada por parte del paciente frente a un estímulo.
- ✓ Se debe revisar si al paciente se le están suministrando medicamentos que puedan llegar a producir un estado de coma inducido farmacológicamente.

Es importante resaltar y tomar en consideración que los reflejos voluntarios o involuntarios (artefactos) afectan la señal electroencefalográfica, lo cual posibilita el aumento del porcentaje de error en la identificación de un determinado patrón de comportamiento en la curva resultante de los datos obtenidos por cada electrodo al momento de la prueba. Por ejemplo, el hecho de que una persona trague, marcaría un cambio significativo en las lecturas, lo cual se podría traducir en una interpretación errónea para una determinada tarea cognitiva. De ahí que sea necesaria la remoción de estos artefactos, de manera que la señal a interpretar se encuentre limpia.

3.1.4. ESTÍMULOS ADECUADOS

Los estímulos comúnmente aplicados para medir la actividad cerebral de un paciente, mediante electroencefalografía, pueden ser:

- ✓ Visuales.
- ✓ Auditivos.
- ✓ Somatosensoriales.

Para el caso de los pacientes en estados derivados del coma, los estímulos más adecuados son los auditivos, ya que otros estímulos como los somatosensoriales, posibilitan la generación de respuestas primitivas en el cerebro más no necesariamente permiten inferir acerca de la presencia o ausencia de conciencia. Por otra parte es importante resaltar que los estímulos visuales también pueden ser de utilidad, pero no son viables en el sentido de que sólo servirían en situaciones reducidas como en el caso de los pacientes con síndrome de enclaustramiento, los cuales pueden hacer uso de la visión a diferencia de la mayoría de los pacientes comatosos.

Por lo anterior se decidió implementar estímulos auditivos para indicarles a los pacientes la tarea cognitiva que debían cumplir. Para este estudio se determinó que se iban a analizar dos estados mentales: el estado de relajación y el de frustración; teniendo en cuenta el siguiente análisis estadístico:

Se procedió a realizar un análisis ANOVA, el cual permite establecer una diferencia o semejanza estadísticamente significativa entre dos variables, con los promedios de las potencias registradas en los electrodos para cada banda de frecuencia y la tarea cognitiva asignada de una serie de pruebas realizadas en pacientes de control. Este análisis estadístico se llevó a cabo mediante el software STATGRAPHICS. La metodología aplicada para realizar las pruebas y el proceso de cálculo de estas potencias se describe en la sección 3.2.1. Este análisis fue aplicado con el fin de determinar la semejanza o diferencia estadística entre el comportamiento de cada electrodo en cada banda de frecuencia respecto a los dos estados mentales implicados. En la tabla 6 se muestra un segmento del total de los datos ingresados en el análisis ANOVA; la totalidad de los datos es una matriz de 60x6 debido a que son 60 pruebas (30 de relajación <R> y 30 de frustración <F>), 5 bandas de frecuencia y el estado mental correspondiente.

Potencia Promedio (dB W)					Estado Mental
Banda Delta	Banda Theta	Banda Alpha	Banda Beta	Banda Gamma	
17.445	11.469	10.884	12.004	5.223	R
18.904	11.147	11.494	13.276	7.119	R
14.644	11.782	11.259	12.002	6.677	R
...
19.911	13.498	14.715	14.772	6.180	F
15.223	10.804	12.101	13.084	5.788	F
13.332	10.602	12.389	12.844	6.897	F
...

Tabla 6. Potencia Promedio en cada Banda de Frecuencia vs Estado Mental.

Para llevar a cabo una comparación más detallada de los resultados del análisis estadístico se procedió a comparar cada banda de frecuencia con los dos estados mentales.

Los resultados del análisis para cada caso se muestran de la tabla 7 a la 26 y de la figura 13 a la 17, presentadas a continuación⁹:

⁹ Todas las tablas y figuras del análisis estadístico fueron obtenidas mediante el software STATGRAPHICS (STATGRAPHICS, 2013).

3.1.4.1. BANDA DELTA VS ESTADO MENTAL

○ Resumen Estadístico

Estado	Recuento	Promedio	Desviación Estándar	Coefficiente de Variación	Mínimo	Máximo	Rango	Sesgo Estandarizado	Curtosis Estandarizada
F	30	15.2805	1.91723	12.5469%	11.9831	19.9171	7.93397	1.86701	0.743893
R	30	15.5396	1.64704	10.599%	11.9349	18.9035	6.96862	0.164127	0.0647861
Total	60	15.4101	1.77685	11.5304%	11.9349	19.9171	7.98215	1.55459	0.377008

Tabla 7. Resumen Estadístico Banda Delta vs Estado Mental

○ Tabla ANOVA para Delta por Estado Mental

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	1.0069	1	1.0069	0.32	0.5767
Intra grupos	185.267	58	3.19426		
Total (Corr.)	186.274	59			

Tabla 8. ANOVA para Delta por Estado Mental.

“La tabla ANOVA descompone la varianza de Delta en dos componentes: un componente entre-grupos y un componente dentro-de-grupos. La razón-F, que en este caso es igual a 0.315221, es el cociente entre el estimado entre-grupos y el estimado dentro-de-grupos. Puesto que el valor-P de la razón-F es mayor o igual que 0.05, no existe una diferencia estadísticamente significativa entre la media de Delta entre un nivel de Estado Mental y otro, con un nivel del 95.0% de confianza” (STATGRAPHICS, 2013).

○ Pruebas de Múltiples Rangos para Delta por Estado

Método: 95.0 porcentaje LSD

Estado	Casos	Media	Grupos Homogéneos
F	30	15.2805	X
R	30	15.5396	X

Tabla 9. Grupos Homogéneos Delta vs Estados Mentales.

Contraste	Sig.	Diferencia	+/- Límites
F - R		-0.259088	0.923727

Tabla 10. Diferencia Significativa entre Estados Mentales.

* indica una diferencia significativa.

“Esta tabla aplica un procedimiento de comparación múltiple para determinar cuáles medias son significativamente diferentes de otras. La mitad inferior de la salida muestra las diferencias estimadas entre cada par de medias. No

hay diferencias estadísticamente significativas entre cualquier par de medias, con un nivel del 95.0% de confianza. Se ha identificado un grupo homogéneo, según la alineación de las X's en columna. No existen diferencias estadísticamente significativas entre aquellos niveles que compartan una misma columna de X's. El método empleado actualmente para discriminar entre las medias es el procedimiento de diferencia mínima significativa (LSD) de Fisher. Con este método hay un riesgo del 5.0% al decir que cada par de medias es significativamente diferente, cuando la diferencia real es igual a 0" (STATGRAPHICS, 2013).

En la figura 13 se muestra un diagrama de caja y bigotes que describe características importantes como la dispersión y simetría de la serie de datos de potencia promedio en la banda Delta para el estado de relajación y frustración.




Figura 13. Gráfico Caja y Bigotes de Banda Delta vs Estado Mental.

3.1.4.2. BANDA THETA VS ESTADO MENTAL

○ Resumen Estadístico

Estado	Recuento	Promedio	Desviación Estándar	Coefficiente de Variación	Mínimo	Máximo	Rango	Sesgo Estandarizado	Curtosis Estandarizada
F	30	11.5012	1.30101	11.3119%	9.32313	13.7168	4.3937	0.295312	-1.31743
R	30	11.3454	1.58512	13.9715%	7.33489	14.5655	7.23063	-1.38155	0.83052
Total	60	11.4233	1.43984	12.6044%	7.33489	14.5655	7.23063	-1.1942	0.394714

Tabla 11. Resumen Estadístico Banda Theta vs Estado Mental.

○ *Tabla ANOVA para Theta por Estado Mental*

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	0.364344	1	0.364344	0.17	0.6787
Intra grupos	121.952	58	2.10261		
Total (Corr.)	122.316	59			

Tabla 12. ANOVA para Theta por Estado Mental.

“Puesto que el valor-P de la razón-F es mayor o igual que 0.05, no existe una diferencia estadísticamente significativa entre la media de Theta entre un nivel de Estado Mental y otro, con un nivel del 95.0% de confianza” (STATGRAPHICS, 2013).

○ *Pruebas de Múltiples Rangos para Theta por Estado*

Método: 95.0 porcentaje LSD

Estado	Casos	Media	Grupos Homogéneos
F	30	11.3454	X
R	30	11.5012	X

Tabla 13. Grupos Homogéneos Theta vs Estados Mentales.

Contraste	Sig.	Diferencia	+/- Límites
F - R		0.155851	0.749441

Tabla 14. Diferencia Significativa entre Estados Mentales.

* indica una diferencia significativa.

“No hay diferencias estadísticamente significativas entre cualquier par de medias, con un nivel del 95.0% de confianza. Se ha identificado un grupo homogéneo, según la alineación de las X's en columna” (STATGRAPHICS, 2013).

En la figura 14 se muestra un diagrama de caja y bigotes que describe características importantes como la dispersión y simetría de la serie de datos de potencia promedio en la banda Theta para el estado de relajación y frustración.




Figura 14. Gráfico Caja y Bigotes de Banda Theta vs Estado Mental.

3.1.4.3. BANDA ALPHA VS ESTADO MENTAL

○ Resumen Estadístico

Estado	Recuento	Promedio	Desviación Estándar	Coeficiente de Variación	Mínimo	Máximo	Rango	Sesgo Estandarizado	Curtosis Estandarizada
F	30	13.7032	1.90517	13.9032%	9.38568	16.6431	7.25746	-1.29333	-0.327024
R	30	10.4675	2.18984	20.9204%	4.5935	14.2334	9.63987	-2.39181	1.84729
Total	60	12.0853	2.60824	21.5819%	4.5935	16.6431	12.0496	-1.80103	0.881227

Tabla 15. Resumen Estadístico Banda Alpha vs Estado Mental.

○ Tabla ANOVA para Alpha por Estado Mental

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	157.046	1	157.046	37.28	0.0000
Intra grupos	244.327	58	4.21253		
Total (Corr.)	401.373	59			

Tabla 16. ANOVA para Alpha por Estado Mental.

“Puesto que el valor-P de la prueba-F es menor que 0.05, existe una diferencia estadísticamente significativa entre la media de Alpha entre un nivel de Estado Mental y otro, con un nivel del 95.0% de confianza” (STATGRAPHICS, 2013).

Método: 95.0 porcentaje LSD

Estado	Casos	Media	Grupos Homogéneos
F	30	10.4675	X
R	30	13.7032	X

Tabla 17. Grupos Homogéneos Alpha vs Estados Mentales.

Contraste	Sig.	Diferencia	+/- Límites
F - R	*	3.23569	1.06079

Tabla 18. Diferencia Significativa entre Estados Mentales.

* indica una diferencia significativa.

“Se ha colocado un asterisco junto a un par (F y R), indicando que éste muestra diferencias estadísticamente significativas con un nivel del 95.0% de confianza. Se han identificado 2 grupos homogéneos según la alineación de las X's en columnas” (STATGRAPHICS, 2013).

En la figura 15 se muestra un diagrama de caja y bigotes que describe características importantes como la dispersión y simetría de la serie de datos de potencia promedio en la banda Alpha para el estado de relajación y frustración.

Gráfico Caja y Bigotes




Figura 15. Gráfico Caja y Bigotes de Banda Alpha vs Estado Mental.

3.1.4.4. BANDA BETA VS ESTADO MENTAL

○ Resumen Estadístico

Estado	Recuento	Promedio	Desviación Estándar	Coefficiente de Variación	Mínimo	Máximo	Rango	Sesgo Estandarizado	Curtosis Estandarizada
F	30	13.5342	0.922504	6.81608%	11.6798	15.7516	4.07182	0.590684	-0.00851239
R	30	11.8656	1.06374	8.96494%	9.52715	13.5685	4.04133	-1.21066	0.0181216
Total	60	12.6999	1.29706	10.2132%	9.52715	15.7516	6.2245	-0.822977	0.297679

Tabla 19. Resumen Estadístico Banda Beta vs Estado Mental.

○ Tabla ANOVA para Beta por Estado Mental

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	41.7655	1	41.7655	42.13	0.0000
Intra grupos	57.4943	58	0.991282		
Total (Corr.)	99.2599	59			

Tabla 20. ANOVA para Beta por Estado Mental.

“Puesto que el valor-P de la prueba-F es menor que 0.05, existe una diferencia estadísticamente significativa entre la media de Beta entre un nivel de Estado Mental y otro, con un nivel del 95.0% de confianza” (STATGRAPHICS, 2013).

Método: 95.0 porcentaje LSD

Estado	Casos	Media	Grupos Homogéneos
F	30	11.8656	X
R	30	13.5342	X

Tabla 21. Grupos Homogéneos Beta vs Estados Mentales.

Contraste	Sig.	Diferencia	+/- Límites
F - R	*	1.66864	0.514584

Tabla 22. Diferencia Significativa entre Estados Mentales.

* indica una diferencia significativa.

“Se ha colocado un asterisco junto a un par, indicando que éste muestra diferencias estadísticamente significativas con un nivel del 95.0% de confianza. Se han identificado 2 grupos homogéneos según la alineación de las X's en columnas” (STATGRAPHICS, 2013).

En la figura 16 se muestra un diagrama de caja y bigotes que describe características importantes como la dispersión y simetría de la serie de datos de potencia promedio en la banda Beta para el estado de relajación y frustración.




Figura 16. Gráfico Caja y Bigotes de Banda Beta vs Estado Mental.

3.1.4.5. BANDA GAMMA VS ESTADO MENTAL

○ Resumen Estadístico

Estado	Recuento	Promedio	Desviación Estándar	Coefficiente de Variación	Mínimo	Máximo	Rango	Sesgo Estandarizado	Curtosis Estandarizada
F	30	7.373	1.03665	14.0601%	5.78829	9.95222	4.16393	2.24612	0.453465
R	30	5.87727	1.1514	19.5908%	3.18877	7.9362	4.74743	-0.895084	-0.060972
Total	60	6.62514	1.32235	19.9597%	3.18877	9.95222	6.76345	-0.06203	1.12188

Tabla 23. Resumen Estadístico Banda Gamma vs Estado Mental.

○ Tabla ANOVA para Delta por Estado Mental

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	33.5581	1	33.5581	27.96	0.0000
Intra grupos	69.6107	58	1.20018		
Total (Corr.)	103.169	59			

Tabla 24. ANOVA para Gamma por Estado Mental.

“Puesto que el valor-P de la prueba-F es menor que 0.05, existe una diferencia estadísticamente significativa entre la media de Gamma entre un nivel de Estado y otro, con un nivel del 95.0% de confianza” (STATGRAPHICS, 2013).

Método: 95.0 porcentaje LSD

Estado	Casos	Media	Grupos Homogéneos
F	30	5.87727	X
R	30	7.373	X

Tabla 25. Grupos Homogéneos Gamma vs Estados Mentales.

Contraste	Sig.	Diferencia	+/- Límites
F - R	*	1.66864	0.514584

Tabla 26. Diferencia Significativa entre Estados Mentales.

* indica una diferencia significativa.

“Se ha colocado un asterisco junto a un par, indicando que éste muestra diferencias estadísticamente significativas con un nivel del 95.0% de confianza. En la parte superior de la página, se han identificado 2 grupos homogéneos según la alineación de las X's en columnas” (STATGRAPHICS, 2013).

En la figura 17 se muestra un diagrama de caja y bigotes que describe características importantes como la dispersión y simetría de la serie de datos de potencia promedio en la banda Gamma para el estado de relajación y frustración.




Figura 17. Gráfico Caja y Bigotes de Banda Gamma vs Estado Mental.

3.1.4.6. RESUMEN DEL ANÁLISIS ANOVA

El resumen del análisis ANOVA para cada caso se muestra en la tabla 27

Banda de Frecuencia	Diferencia significativa Entre las medias de los Dos Estados (R y F)	
	Si	No
<i>Delta</i>		X
<i>Theta</i>		X
<i>Alpha</i>	X	
<i>Beta</i>	X	
<i>Gamma</i>	X	

Tabla 27. Resumen del Análisis ANOVA de los diferentes casos

Este análisis determina entonces diferencias estadísticamente significativas por lo menos en tres de las cinco bandas de frecuencia analizadas entre los dos estados mentales propuestos. Esto permite inferir que en general el estado de relajación y el estado de frustración son distinguibles entre sí, lo que posibilita un posterior análisis de clasificación mediante la red neuronal artificial propuesta en la sección 3.2.2 y 3.3

3.2. DISEÑO DEL MODELO

En este capítulo se exponen las subsecciones necesarias para el planteamiento del modelo.

3.2.1. OBTENER LOS REGISTROS REGULARES DE PACIENTES SANOS:

El protocolo planteado para esta tarea fue el siguiente: se realizó una prueba a 30 personas conscientes a las cuales se les indicó que cerraran los ojos con el headset puesto. Luego se les pidió que se imaginasen en un estado de relajación y posteriormente en un estado de frustración. Cada tarea se grabó durante 6 segundos, tomando periodos de receso de medio minuto entre las dos situaciones propuestas.

Se obtuvo entonces un registro por cada situación imaginada para cada individuo de prueba, obteniendo 60 series de registros en total: 30 de relajación y 30 de frustración respectivamente. Para ello se siguió el procedimiento recomendado por el Centro Computacional de Neurociencia SWARTZ (SCCN) (Neuroscience, 2013):

- ✓ Primero se obtuvo el RAW DATA que registra el comportamiento de los electrodos durante la prueba. Esto se realizó mediante la aplicación Testbench que viene con el software del Emotiv EPOC. En la figura 18 se muestran los registros recolectados de una de las pruebas realizadas:




Figura 18. RAW DATA

Nótese que los datos no se encuentran normalizados y solo contienen algunos filtros muy básicos que el Emotiv realiza.

- ✓ Luego se aplicaron los filtros correspondientes, tales como: filtro pasa bajo para eliminar el ruido de alta frecuencia, filtro de remoción de la línea de base y por último se aplica el análisis de componentes independientes (ICA). Además se aplicó un recorte manual de datos con el fin de eliminar los segmentos de datos erróneos que no fueron eliminados con los filtros anteriormente mencionados. Este proceso de filtrado se llevó a cabo con EEGLab, un toolbox para MATLAB desarrollado por el SCCN. Posterior a este preprocesamiento de datos se disminuyó la duración de todas las pruebas a un número total de 300 muestras con el fin de estandarizar la duración de los registros preprocesados; esto debido a que los segmentos erróneos recortados en las pruebas eran diferentes.

En la figura 19 se muestra un ejemplo de uno de los segmentos erróneos que se recortó manualmente (en color cian) con el fin de evitar una posterior interpretación errónea de los registros.




Figura 19. Ejemplo de un segmento de datos erróneo recortado.

- ✓ Con los registros preprocesados se continuó con la determinación de las potencias relativas de cada banda de frecuencia de la siguiente forma: primero se realizó un periodograma modificado, el cual empleó una función de ventaneo de Hann para evitar las discontinuidades al inicio y al final de la serie de datos obtenida en cada prueba. Con la nueva serie de datos que nos proporcionó el periodograma (frecuencia vs potencia) se convirtieron las potencias en decibelios y se procedió a tabular los resultados. Este proceso de determinación de las potencias relativas de las bandas de frecuencia se llevó a cabo mediante una función programada en MATLAB, la cual se puede ver con más detalle en el anexo 5. En la tabla 28 se muestra un ejemplo del espectro de potencia resultante, para una de las pruebas realizadas, siguiendo el proceso descrito anteriormente.

Electrodos (14)

Hz	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
0.0	3.03	3.23	6.72	-3.54	-27.88	8.39	-4.33	16.13	16.82	22.79	12.68	-13.18	8.78	-2.68
0.4	16.05	14.23	15.42	13.45	13.81	-9.35	14.31	11.31	12.63	18.16	19.01	17.00	18.13	14.82
...
64.0	-45.34	-40.82	-32.73	-36.01	-49.47	-37.29	-41.79	-54.91	-48.14	-34.20	-30.61	-33.86	-34.55	-49.82

Potencia (dB W)

Tabla 28. Frecuencia vs Potencia.

En la figura 20 se expone un ejemplo del espectro de potencia obtenido para cada electrodo en una de las pruebas tratadas:




Figura 20. Frecuencia vs Potencia de la Señal (Neuroscience, 2013).

- ✓ Por último se determinan las potencias relativas de cada banda de frecuencia, esto se hace definiendo los rangos de frecuencia de cada banda (por ejemplo, las ondas delta cubren las frecuencias entre 0 Hz y 4 Hz) y realizando un promedio de las potencias en dicho rango, esto teniendo en cuenta la frecuencia de muestreo. La tabla 29 es un ejemplo de una de las pruebas en donde se muestran las potencias de las bandas de frecuencia obtenidas de cada periodograma realizado para las series de datos de cada electrodo; también se incluyen el promedio de las potencias registradas en los electrodos para cada banda de frecuencia y el total de las potencias de las bandas de frecuencias para cada electrodo.

Banda de Frecuencia	Potencia (dB W)														Promedio
	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4	
Delta	17.69	11.30	14.77	10.15	20.78	9.50	15.93	18.71	10.04	17.48	13.04	14.38	14.05	17.22	14.64
Theta	14.27	9.34	12.73	5.29	11.31	9.50	12.38	11.08	10.95	12.97	13.05	15.10	11.95	15.02	11.78
Alpha	11.46	7.85	9.57	8.38	9.42	9.32	13.53	12.11	10.26	12.70	13.56	13.67	13.07	12.73	11.26
Beta	11.47	10.51	12.07	12.03	10.93	11.18	13.34	12.99	11.79	11.50	12.63	13.43	11.81	12.34	12.00
Gamma	5.59	5.80	6.93	6.04	6.45	5.52	4.26	7.65	7.97	6.86	9.15	6.90	6.89	7.48	6.68
Total	60.49	44.80	56.07	41.90	58.89	45.03	59.43	62.53	51.01	61.50	61.43	63.48	57.78	64.79	

Tabla 29. Potencia en las Bandas de Frecuencia

Es de recalcar que los promedios tabulados en esta tabla son unas de las entradas de la red neuronal artificial para el proceso de identificación y clasificación de un estado cognitivo. En total, la base de datos de las pruebas que ingresan a la red neuronal sería entonces una matriz de 60x5, teniendo en cuenta que se tomaron 60 pruebas en total y que cada prueba arroja 5 promedios correspondientes a cada banda de frecuencia. La disposición de estas pruebas se expone en la sección 3.2.2.

3.2.2. PLANTEAR EL MODELO PARA CLASIFICAR LOS PATRONES DE ACTIVACIÓN CEREBRAL

El modelo desarrollado debe contar con las siguientes características para cumplir el propósito general:

- ✓ Almacenar los datos correspondientes a los promedios de las potencias registradas en los electrodos para cada banda de frecuencia en las diferentes pruebas.
- ✓ Disponer de la mitad de las pruebas (30 pruebas) para el proceso de aprendizaje de la red neuronal artificial y la otra mitad (30 pruebas) para validar el modelo. Tener en cuenta que tanto el proceso de aprendizaje como el proceso de validación cuentan con el mismo número de pruebas de relajación y frustración. En la figura 21 se expone más comprensivamente la disposición de las pruebas.

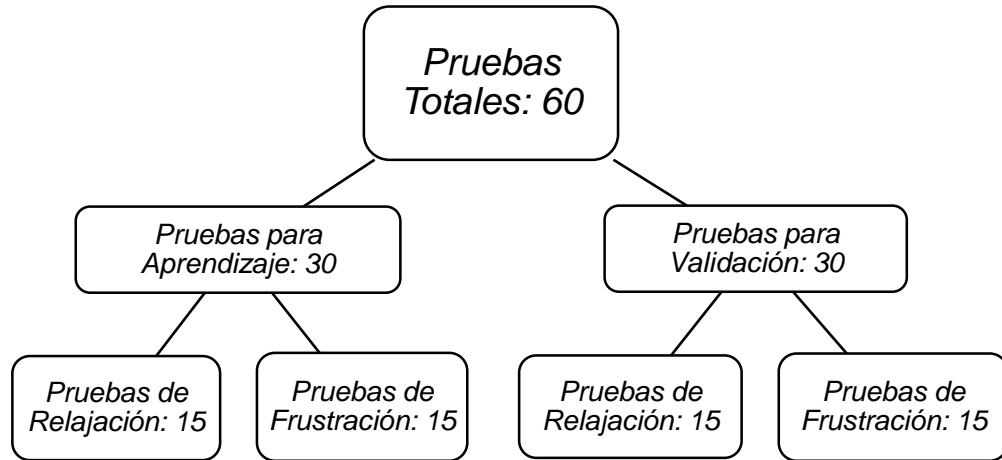


Figura 21. Disposición de las Pruebas Recolectadas.

De esta forma se asegura que el conjunto de datos para el aprendizaje sea significativo, en el sentido que contempla un número adecuado de pruebas, y además que sea representativo, por el hecho de contar con la misma cantidad de pruebas de los dos tipos de datos (relajación y frustración).

- ✓ Aleatorización de las pruebas con el fin de no sesgar el entrenamiento de la red neuronal, es decir sortear entre las pruebas de relajación y frustración pero manteniendo igual el número de pruebas de estos dos estados.
- ✓ Identificar y asociar las entradas ingresadas a la red (promedio de la potencia de cada banda de frecuencia) con la salida esperada (tarea cognitiva realizada) con el fin de diferenciar los patrones de activación (relajación y frustración). Esto se resume en un aprendizaje supervisado ya que se conocen las entradas y las salidas del conjunto de datos de entrenamiento, de modo que se guía el proceso de aprendizaje de la red neuronal artificial constantemente. Además este aprendizaje se realiza de forma OFF LINE, por el hecho de que los registros no pueden entrar puros sino que requieren de un preprocesamiento cauteloso que garantice la corrección de todos los factores de error.
- ✓ Finalizar el proceso de aprendizaje con un error cuadrático medio (MSE) mínimo.
- ✓ Guardar las ponderaciones sinápticas (también llamadas pesos) durante el proceso de aprendizaje para una posterior validación del modelo.

3.3. DESARROLLO DEL MODELO PARA CLASIFICAR LOS PATRONES DE ACTIVACIÓN CEREBRAL

Se plantearon dos redes neuronales artificiales a evaluar en la búsqueda de la mejor respuesta de aprendizaje y clasificación sobre las series de datos propuestas. Las redes neuronales propuestas fueron la red perceptrón multicapa (MLP) y la red de base radial (RBF). La secuencia y modo de operación de estas redes neuronales se expone en la sección 1.3.8.1.1.1. y 1.3.8.1.2.1.

Estas redes neuronales artificiales poseen una estructura flexible que permite la generación de modelos predictivos, a través de un entrenamiento, en donde se construyen diferentes conexiones sinápticas que determinan el comportamiento de la red ante determinadas entradas.

3.3.1. RED PERCEPTRÓN MULTICAPA (MLP)

La arquitectura de la red perceptrón multicapa que se empleó fue la siguiente: Cinco neuronas en la capa de entrada que corresponden a las potencias promedio en cada banda de frecuencia, una capa oculta con tres neuronas ocultas que son la suma ponderada de las entradas, y una neurona en la capa de salida que corresponde al estado mental según la serie de entradas en la capa de entrada. Las diferentes ponderaciones sinápticas (pesos) que intervienen en las conexiones entre la capa de entrada y la capa oculta se nombran como $W_{j,i}$ (j:referencia de la neurona oculta, i: referencia de la neurona de entrada) y las ponderaciones sinápticas entre la capa oculta y la capa de salida se nombran como C_j (j: referencia de la neurona oculta). En la figura 22 se muestra la arquitectura de la red perceptrón multicapa propuesta.

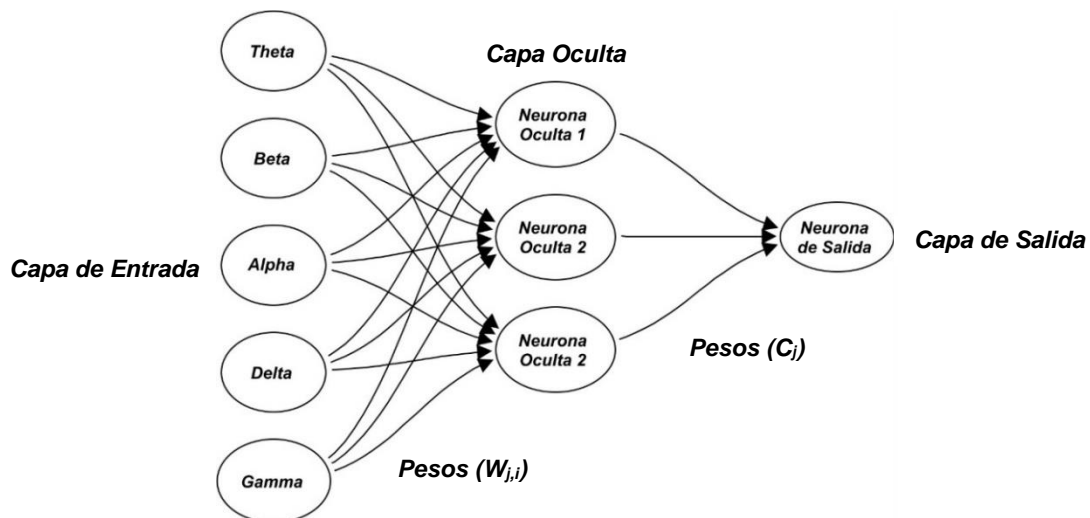


Figura 22. Arquitectura de la red perceptrón multicapa.

Como solo se analizaron dos estados mentales se definió únicamente una neurona de salida, la cual contiene una función de salida escalón que presenta una salida binaria con un valor de 0 si el estado es relajación y de 1 si el estado es frustración. En la tabla 30 se

muestran las series de datos del proceso de aprendizaje (recordar que el proceso de aprendizaje se diseñó para tomar el 50% de las pruebas) y las series de datos del proceso de validación.

Prueba	Nodos de Entrada					Nodo de Salida
	Delta	Theta	Alpha	Beta	Gamma	
1	13.332	10.602	12.389	12.844	6.897	1
2	14.918	10.309	12.880	13.487	6.583	1
3	14.011	11.968	9.439	11.376	6.066	0
...
28	16.931	11.940	9.139	11.856	7.388	0
29	15.131	12.883	14.157	12.787	7.380	1
30	15.381	11.371	13.579	14.944	9.496	1
31	13.837	12.303	15.421	13.195	6.621	1
32	15.465	11.833	12.298	13.446	6.161	0
33	13.142	11.145	9.168	10.497	4.942	0
...
58	18.443	10.436	11.545	11.759	6.543	0
59	13.153	10.836	9.386	11.680	6.610	1
60	15.619	9.623	4.594	9.565	3.866	0

Series de Datos para Aprendizaje

Series de Datos para Validar

Tabla 30. Base de Datos de las series de datos para el entrenamiento y validación de la red perceptrón multicapa. En verde se muestran las salidas que se espera que la red neuronal aprenda según las entradas mostradas.

Los parámetros asociados al proceso de aprendizaje de la red neuronal artificial se muestran en la tabla 31.

Parámetro	Valor
Número de series de datos totales	60
Número de neuronas de entrada	5
Número de neuronas ocultas	3
Factor de Aprendizaje	0.0005
Porcentaje de series de datos a validar	50%

Tabla 31. Parámetros asociados al proceso de aprendizaje de la red perceptrón multicapa.

Nota: Al indicar que el porcentaje de series de datos a validar es del 50%, la red neuronal artificial toma la primera mitad de las pruebas (30 pruebas) para el proceso de aprendizaje.

Los criterios de parada considerados en el entrenamiento se presentan en la tabla 32.

Criterios de Parada	Valor
<i>Número máximo de iteraciones</i>	1000
<i>Error Cuadrático Medio</i>	< 0.1
<i>Incremento del MSE</i>	$MSE_{actual} - MSE_{anterior} > 0$

Tabla 32. Criterios de parada de la red perceptrón multicapa.

Al realizar el entrenamiento, el criterio de parada que detuvo el proceso de aprendizaje fue el número de iteraciones máximo determinado, obteniendo un error cuadrático medio de 1.48 aproximadamente.

La curva del error cuadrático medio contra las iteraciones se muestra en la figura 23.




Figura 23. Iteraciones vs Error Cuadrático Medio de la red perceptrón multicapa.

En la tabla 33 se muestran las salidas aprendidas por la red perceptrón multicapa contra las salidas esperadas en las pruebas de entrenamiento.

Prueba	Entradas					Salidas	
	Delta	Theta	Alpha	Beta	Gamma	Salida Esperada	Salida Aprendida
1	13.332	10.602	12.389	12.844	6.897	1	1
2	14.918	10.309	12.880	13.487	6.583	1	1
3	14.011	11.968	9.439	11.376	6.066	0	0
4	16.516	10.344	11.032	12.375	5.814	0	0
5	11.983	10.068	14.647	12.677	8.470	1	1
6	13.642	11.069	13.903	13.800	6.885	1	1
7	13.755	10.189	11.960	13.407	8.420	1	1
8	16.328	9.156	8.368	10.985	6.030	0	0
9	16.560	11.601	12.110	13.568	5.909	0	0
10	18.611	12.825	11.230	11.817	5.447	0	0
11	14.033	12.274	10.354	11.127	5.211	0	0
12	17.445	11.469	10.884	12.004	5.223	0	0
13	14.295	9.756	9.942	12.127	6.340	0	0
14	16.537	13.320	10.441	12.681	7.410	1	0
15	15.164	12.018	12.291	12.779	7.210	0	1
16	14.332	10.844	10.987	11.206	4.581	0	0
17	19.911	13.498	14.715	14.772	6.180	1	0
18	17.169	9.551	15.013	13.906	6.694	1	1
19	16.258	12.268	12.062	11.683	3.811	0	0
20	14.917	10.325	13.762	13.637	7.167	1	1
21	15.610	12.009	11.405	12.923	5.596	0	0
22	15.223	10.804	12.101	13.084	5.788	1	1
23	16.533	12.746	11.115	11.943	7.936	0	0
24	13.396	12.421	15.557	15.752	9.313	1	1
25	13.487	10.524	15.966	13.633	7.218	1	1
26	11.935	7.933	4.852	9.997	5.188	0	0
27	15.604	13.717	16.643	13.693	6.990	1	1
28	16.931	11.940	9.139	11.856	7.388	0	0
29	15.131	12.883	14.157	12.787	7.380	1	1
30	15.381	11.371	13.579	14.944	9.496	1	1

Tabla 33. Salidas aprendidas por la red perceptrón multicapa sobre las pruebas de entrenamiento. En verde se muestran los aciertos y en rojo los desaciertos.

De las 30 pruebas que se propusieron en el aprendizaje, la red perceptrón multicapa aprendió correctamente 27 pruebas, lo que significa el 90% del total. Los resultados de los aciertos y desaciertos sobre el entrenamiento de la red neuronal con la serie de datos de aprendizaje se muestran en la tabla 34.

Estado Mental	Aciertos	Desaciertos	Total
<i>Relajación</i>	14	1	15
<i>Frustración</i>	13	2	15
Total	27	3	30

Tabla 34. Resultados sobre el entrenamiento de la red perceptrón multicapa con las series de datos de aprendizaje propuestas.

3.3.2. RED DE BASE RADIAL (RBF)

La arquitectura de la red de base radial que se empleó fue la siguiente: Cinco nodos de entrada que corresponden a las potencias promedio normalizadas (0 a 1) en cada banda de frecuencia, una capa oculta que contiene una función de activación gaussiana con tres neuronas ocultas, y una neurona en la capa de salida que corresponde al estado mental asociado a la serie de entradas en la capa de entrada. Las ponderaciones sinápticas (pesos) que intervienen en las conexiones entre la capa oculta y la capa de salida se nombran como C_j (j : referencia de la neurona oculta), los centros de la función de base radial se nombran como $XC_{j,i}$. Se asume una desviación unitaria ($d=1$). Para la red neuronal de base radial se empleó una función de activación gaussiana. En la figura 24 se muestra la arquitectura de la red de base radial propuesta.

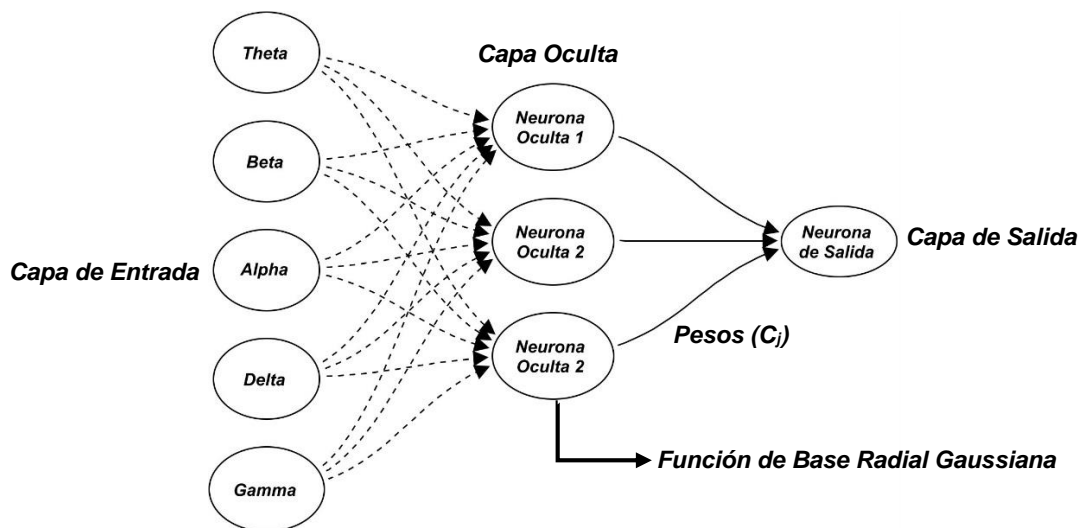


Figura 24. Arquitectura de la red de base radial.

En la tabla 35 se muestran las series de datos del proceso de aprendizaje (recordar que el proceso de aprendizaje se diseñó para tomar el 50% de las pruebas) y las series de datos del proceso de validación.

Prueba	Nodos de Entrada					Nodo de Salida
	Delta	Theta	Alpha	Beta	Gamma	
1	0.669	0.728	0.744	0.815	0.693	1
2	0.749	0.708	0.774	0.856	0.661	1
3	0.703	0.822	0.567	0.722	0.610	0
...
28	0.850	0.820	0.549	0.753	0.742	0
29	0.760	0.884	0.851	0.812	0.742	1
30	0.772	0.781	0.816	0.949	0.954	1
31	0.695	0.845	0.927	0.838	0.665	1
32	0.776	0.812	0.739	0.854	0.619	0
33	0.660	0.765	0.551	0.666	0.497	0
...
58	0.926	0.716	0.694	0.747	0.657	0
59	0.660	0.744	0.564	0.741	0.664	1
60	0.784	0.661	0.276	0.607	0.388	0

Series de Datos para Aprendizaje

Series de Datos para Validar

Tabla 35. Base de Datos de las series de datos para el entrenamiento y validación de la red de base radial. En verde se muestran las salidas que se espera que la red neuronal aprenda según las entradas mostradas.

Los parámetros asociados al proceso de aprendizaje de la red de base radial se muestran en la tabla 36.

Parámetro	Valor
Número de series de datos totales	60
Número de neuronas de entrada	5
Número de neuronas ocultas	3
Factor de Aprendizaje	0.03
Porcentaje de series de datos a validar	50%

Tabla 36. Parámetros asociados al proceso de aprendizaje de la red de base radial.

Nota: Al indicar que el porcentaje de series de datos a validar es del 50%, la red neuronal artificial toma la primera mitad de las pruebas (30 pruebas) para el proceso de aprendizaje. Los criterios de parada considerados en el entrenamiento se presentan en la tabla 37.

Criterios de Parada	Valor
Número máximo de iteraciones	1000
Error Cuadrático Medio (MSE)	< 0.1
Incremento del MSE	$MSE_{\text{actual}} - MSE_{\text{anterior}} > 0$

Tabla 37. Criterios de parada de la red de base radial.

Al realizar el entrenamiento, el criterio de parada que detuvo el proceso de aprendizaje fue el incremento del error cuadrático medio, terminando el proceso de aprendizaje en la iteración número 341 y obteniendo un error cuadrático medio de 1.43. La curva del error cuadrático medio contra las iteraciones se muestra en la figura 25.




Figura 25. Iteraciones vs Error Cuadrático Medio de la red de base radial.

En la tabla 38 se muestra las salidas aprendidas por la red de base radial contra las salidas esperadas en las pruebas de entrenamiento.

Prueba	Entradas					Salidas	
	Delta	Theta	Alpha	Beta	Gamma	Salida Esperada	Salida Aprendida
1	0.669	0.728	0.744	0.815	0.693	1	1
2	0.749	0.708	0.774	0.856	0.661	1	1
3	0.703	0.822	0.567	0.722	0.610	0	0
4	0.829	0.710	0.663	0.786	0.584	0	0
5	0.602	0.691	0.880	0.805	0.851	1	1
6	0.685	0.760	0.835	0.876	0.692	1	1
7	0.691	0.700	0.719	0.851	0.846	1	1
8	0.820	0.629	0.503	0.697	0.606	0	0
9	0.831	0.796	0.728	0.861	0.594	0	1
10	0.934	0.881	0.675	0.750	0.547	0	0
11	0.705	0.843	0.622	0.706	0.524	0	0
12	0.876	0.787	0.654	0.762	0.525	0	0
13	0.718	0.670	0.597	0.770	0.637	0	0
14	0.830	0.914	0.627	0.805	0.745	1	0
15	0.761	0.825	0.739	0.811	0.724	0	1
16	0.720	0.745	0.660	0.711	0.460	0	0
17	1.000	0.927	0.884	0.938	0.621	1	1
18	0.862	0.656	0.902	0.883	0.673	1	1
19	0.816	0.842	0.725	0.742	0.383	0	0
20	0.749	0.709	0.827	0.866	0.720	1	1
21	0.784	0.824	0.685	0.820	0.562	0	0
22	0.764	0.742	0.727	0.831	0.582	1	0
23	0.830	0.875	0.668	0.758	0.797	0	0
24	0.673	0.853	0.935	1.000	0.936	1	1
25	0.677	0.723	0.959	0.866	0.725	1	1
26	0.599	0.545	0.292	0.635	0.521	0	0
27	0.783	0.942	1.000	0.869	0.702	1	1
28	0.850	0.820	0.549	0.753	0.742	0	0
29	0.760	0.884	0.851	0.812	0.742	1	1
30	0.772	0.781	0.816	0.949	0.954	1	1

Tabla 38. Salidas aprendidas por la red de base radial sobre las pruebas de entrenamiento. En verde se muestran los aciertos y en rojo los desaciertos.

De las 30 pruebas que se propusieron en el aprendizaje, la red de base radial aprendió correctamente 26 pruebas, lo que significa el 86.67% del total. Los resultados de los aciertos y desaciertos sobre el entrenamiento de la red neuronal con la serie de datos de aprendizaje se muestran en la tabla 39.

Estado Mental	Aciertos	Desaciertos	Total
<i>Relajación</i>	13	2	15
<i>Frustración</i>	13	2	15
<i>Total</i>	26	3	30

Tabla 39. Resultados sobre el entrenamiento de la red de base radial con las series de datos de aprendizaje propuestas.

3.3.3. RESUMEN GENERAL DE LAS REDES NEURONALES ARTIFICIALES EMPLEADAS

Las dos redes neuronales artificiales, empleadas anteriormente en el aprendizaje de una serie de pruebas destinadas al entrenamiento, arrojaron porcentajes de asertividad de más del 86%, reflejando un buen aprendizaje en general por parte de ambas. Sin embargo, sí se evidenció una diferencia significativa respecto del proceso de aprendizaje de cada una, siendo la red de base radial más rápida en obtener un error cuadrático medio de 1.43 en una cantidad de iteraciones menor comparada con la red perceptrón multicapa. Es de aclarar que estos porcentajes de asertividad tienden a ser muy optimistas por el hecho de que solo se están evaluando dos estados mentales, lo que conlleva a un aumento en exceso en la tasa de clasificación. Por lo tanto, este porcentaje no es determinante para la selección de una u otra red neuronal, sino que cada red debe ser evaluada a través de una serie de pruebas externas a las destinadas en el entrenamiento, que permitan determinar realmente el porcentaje de asertividad que posee cada una.

4. VALIDACIÓN DEL MODELO

Con las ponderaciones sinápticas construidas en el proceso de aprendizaje de ambas redes neuronales se procedió a validar el entrenamiento mediante una serie de pruebas específicamente reservadas para este proceso.

4.1. RED PERCEPTRÓN MULTICAPA (MLP)

Finalizado el proceso de aprendizaje con un error cuadrático medio de 1.48, se procedió a validar el funcionamiento de la red perceptrón multicapa. Los resultados del proceso de validación con el 50% de las pruebas restantes se muestra a en la tabla 40.

Prueba	Entradas					Salidas	
	Delta	Theta	Alpha	Beta	Gamma	Salida Esperada	Salida Validada
31	13.837	12.303	15.421	13.195	6.621	1	1
32	15.465	11.833	12.298	13.446	6.161	0	0
33	13.142	11.145	9.168	10.497	4.942	0	0
34	16.624	11.157	9.919	13.717	7.458	1	0
35	14.282	11.600	9.203	11.718	5.972	0	0
36	16.357	9.323	15.389	13.125	7.708	1	1
37	16.048	12.904	15.565	14.646	6.626	1	1
38	16.281	13.870	13.923	12.581	7.585	0	1
39	15.384	11.109	13.136	12.328	6.928	1	1
40	16.236	14.566	11.634	12.610	6.756	0	0
41	13.970	11.475	13.897	12.779	7.467	1	1
42	14.506	12.713	12.330	13.121	4.612	0	0
43	18.904	11.147	11.494	13.276	7.119	0	0
44	14.234	12.493	14.801	13.006	6.389	1	1
45	12.780	7.335	7.979	9.527	3.189	0	0
46	16.131	12.200	11.320	14.593	9.952	1	1
47	14.905	9.761	10.415	12.155	6.230	0	0
48	18.533	13.580	15.694	13.015	6.407	1	1
49	14.644	11.782	11.259	12.002	6.677	0	0
50	14.260	11.962	13.698	12.001	6.352	1	1
51	19.917	12.383	12.149	14.123	7.281	1	0
52	15.683	12.553	10.994	11.055	5.973	0	0
53	15.963	12.431	7.746	11.789	5.659	0	0
54	14.773	10.417	14.233	13.101	7.284	0	1
55	15.808	9.709	16.427	14.608	9.010	1	1
56	13.191	10.207	14.265	14.364	7.359	1	1
57	16.580	12.746	12.312	13.744	8.131	1	0

Prueba	Entradas					Salidas	
	Delta	Theta	Alpha	Beta	Gamma	Salida Esperada	Salida Validada
58	18.443	10.436	11.545	11.759	6.543	0	0
59	13.153	10.836	9.386	11.680	6.610	1	0
60	15.619	9.623	4.594	9.565	3.866	0	1

Tabla 40. Resultados sobre la validación de la red perceptrón multicapa con las series de datos destinados para validar el modelo. En verde se muestran los aciertos y en rojo los desaciertos.

De las 30 pruebas que se propusieron para la validación, la red perceptrón multicapa validó correctamente 23 pruebas, lo que representa un 76.67% de asertividad. Esto quiere decir que, en general, la red clasifica correctamente tres de cada cuatro casos. Los resultados que indican el número de aciertos y desaciertos sobre la validación de la red perceptrón multicapa se muestran en la tabla 41.

Estado Mental	Aciertos	Desaciertos	Total
Relajación	12	3	15
Frustración	11	4	15
Total	23	7	30

Tabla 41. Validación sobre el 50% de pruebas restantes de la red perceptrón multicapa.

4.2. RED DE BASE RADIAL (RBF)

Finalizado el proceso de aprendizaje con un error cuadrático medio de 1.43, se procedió a validar el funcionamiento de la red de base radial. Los resultados del proceso de validación con el 50% de las pruebas restantes se muestra a en la tabla 42.

Prueba	Entradas					Salidas	
	Delta	Theta	Alpha	Beta	Gamma	Salida Esperada	Salida Aprendida
31	0.695	0.845	0.927	0.838	0.665	1	1
32	0.776	0.812	0.739	0.854	0.619	0	1
33	0.660	0.765	0.551	0.666	0.497	0	0
34	0.835	0.766	0.596	0.871	0.749	1	0
35	0.717	0.796	0.553	0.744	0.600	0	0
36	0.821	0.640	0.925	0.833	0.775	1	1
37	0.806	0.886	0.935	0.930	0.666	1	1
38	0.817	0.952	0.837	0.799	0.762	0	1
39	0.772	0.763	0.789	0.783	0.696	1	1
40	0.815	1.000	0.699	0.801	0.679	0	0
41	0.701	0.788	0.835	0.811	0.750	1	1
42	0.728	0.873	0.741	0.833	0.463	0	0
43	0.949	0.765	0.691	0.843	0.715	0	0

Prueba	Entradas					Salidas	
	Delta	Theta	Alpha	Beta	Gamma	Salida Esperada	Salida Aprendida
44	0.715	0.858	0.889	0.826	0.642	1	1
45	0.642	0.504	0.479	0.605	0.320	0	0
46	0.810	0.838	0.680	0.926	1.000	1	1
47	0.748	0.670	0.626	0.772	0.626	0	0
48	0.931	0.932	0.943	0.826	0.644	1	1
49	0.735	0.809	0.677	0.762	0.671	0	0
50	0.716	0.821	0.823	0.762	0.638	1	1
51	1.000	0.850	0.730	0.897	0.732	1	1
52	0.787	0.862	0.661	0.702	0.600	0	0
53	0.801	0.853	0.465	0.748	0.569	0	0
54	0.742	0.715	0.855	0.832	0.732	0	1
55	0.794	0.667	0.987	0.927	0.905	1	1
56	0.662	0.701	0.857	0.912	0.739	1	1
57	0.832	0.875	0.740	0.873	0.817	1	1
58	0.926	0.716	0.694	0.747	0.657	0	0
59	0.660	0.744	0.564	0.741	0.664	1	0
60	0.784	0.661	0.276	0.607	0.388	0	0

Tabla 42. Resultados sobre la validación de la red de base radial con las series de datos destinados para validar el modelo. En verde se muestran los aciertos y en rojo los desaciertos.

De las 30 pruebas que se propusieron para la validación, la red de base radial validó correctamente 25 pruebas, lo que representa un 83.33% de asertividad. Esto quiere decir que, en general, la red clasifica correctamente cuatro de cada cinco casos. Los resultados que indican el número de aciertos y desaciertos sobre la validación de la red de base radial se muestran en la tabla 43.

Estado Mental	Aciertos	Desaciertos	Total
Relajación	12	3	15
Frustración	13	2	15
Total	25	5	30

Tabla 43. Validación sobre el 50% de pruebas restantes de la red de base radial.

4.3. RESUMEN GENERAL DE LA VALIDACIÓN DE LAS REDES NEURONALES ARTIFICIALES

Las validaciones realizadas por las redes neuronales artificiales, con las pruebas reservadas para este fin, arrojaron como resultado porcentajes de asertividad por encima del 76%, siendo la red de base radial la que obtuvo el mejor resultado (83.33%), indicando un mejor desempeño en el proceso de clasificación de los dos estados mentales propuestos en comparación con la red perceptrón multicapa.

4.4. VALIDACIÓN DEL MODELO CON PACIENTES INCONSCIENTES

La validación del modelo frente a pacientes en estado de inconsciencia conlleva en primer lugar un análisis para determinar si es factible y tiene sentido llevar a cabo una examinación y posterior comparación del modelo computacional desarrollado con pacientes conscientes; el cual se presenta a continuación:

Estudios enfocados en la neurociencia y más específicamente en el análisis de diferentes estados cognitivos como los de (Alkire MT H. R., 1995) y (Alkire MT P. C., 1999), han demostrado que el metabolismo cerebral y las activaciones neuronales de los pacientes en estado de inconsciencia no reflejan respuestas significativas frente a estímulos externos. Así mismo, los pacientes en un estado de sueño profundo reflejan una caída del metabolismo cerebral hasta cerca del 40% de los valores normales, como lo demuestran los estudios de (Maquet P, 1997) y (Buchsbaum MS, 1989). Por lo anterior, no es pertinente realizar la validación del modelo con este tipo de pacientes ya que los estímulos auditivos serían inútiles en el sentido de que no generarían una respuesta que permitiese inferir alguno de los estados mentales propuestos para el modelo.

5. PROTOCOLO DE EVALUACIÓN DE LOS PACIENTES

Para llevar a cabo correctamente la evaluación de los pacientes y así obtener una respuesta óptima y veraz del modelo se debe seguir el siguiente protocolo de evaluación:

1. Asegurar que el sitio en el que se va a llevar a cabo la valoración sea lo más tranquilo y silencioso posible de forma que los únicos estímulos auditivos que reciba el paciente sean propios de la valoración y no externos a ésta.
2. Revisar y asegurar que al paciente no se le hayan suministrado agentes anestésicos que puedan inducir un estado de sueño profundo o inhibir su respuesta frente a estímulos.
3. Situar la BCI en la cabeza del paciente de manera que ninguno de los electrodos reciban señales externas que puedan afectar las lecturas (por ejemplo, compresión del electrodo con la cabeza del paciente y la cama).
4. Verificar que la calidad de la señal recibida por cada electrodo sea excelente.
5. Realizar una exploración neurofisiológica enfocada en la funcionalidad del sistema sensorial acústico o auditivo. Se recomienda hacer una prueba de potenciales evocados auditivos (PEA), es decir, evaluar la respuesta del sistema nervioso central a diferentes estímulos auditivos normalizados (se puede emplear la misma BCI a usar en la valoración), con el objetivo de determinar la viabilidad de la prueba.¹⁰
6. Contextualizar al paciente acerca de la valoración que se le va a realizar, explicándole que primero se le indicará que piense en situaciones relajantes durante un tiempo determinado (6 segundos) y luego que piense en situaciones frustrantes durante el mismo tiempo; lo anterior debe repetirse 5 veces.
7. Aplicar el modelo a los datos obtenidos del paciente teniendo en cuenta la rigurosidad que se debe seguir en el procesamiento de éstos. Tener presente el porcentaje de asertividad arrojado por el modelo para el paciente, de acuerdo a éste evaluar la pertinencia de continuar con la parte comunicativa del protocolo.

A continuación se presenta la sección comunicativa del protocolo; es recomendable que el porcentaje de asertividad arrojado en el numeral 7 sea superior al 75%, de lo contrario no se recomienda proceder con esta sección. Es importante aclarar que esta fase es experimental y por esto no debería ser empleada para lanzar criterios definitivos sobre el estado de conciencia del paciente, ya que como se mencionó anteriormente existen múltiples factores de error que pueden sesgar los resultados:

¹⁰ Para tener mayor claridad en relación a la prueba de potenciales evocados auditivos referirse al libro *“Electric response audiometry in clinical practice”* de Solomon Abramovich y A.R.D. Thornton.

8. Contextualizar nuevamente al paciente, explicándole que ahora se va a realizar una prueba comunicativa, en la cual deberá pensar en situaciones relajantes para responder afirmativamente, “sí”, y en situaciones frustrantes para responder negativamente, “no”, durante 10 segundos, frente a una serie de preguntas.
9. Proceder a hacer la serie de preguntas sí/no que sean verificables. Se recomienda preparar con anterioridad la serie de preguntas, obteniendo la información de la familia del paciente; pueden ser preguntas como: “¿Tiene hermanos?”, “¿Usted se llama (nombre del paciente)?”, “¿Está usted casado?”, “¿Tiene hijos?”.
10. Aplicar el modelo nuevamente para las series de pruebas anteriores. Ahora cada respuesta dada por el paciente será clasificada por el modelo como un sí (relajación) o un no (frustración).
11. Verificar cuántas de las respuestas fueron correctas.
12. En el caso de haber acertado en más del 75% de las preguntas se podría llegar a considerar la posibilidad de que el paciente esté consciente. En este punto se recomienda replicar el modelo periódicamente con el fin de corroborar el estado cognitivo inferido por éste.

A continuación se presenta la sección de finalización del protocolo:

13. Comentarle al paciente que la prueba ha terminado y que se va a proceder a retirarle la BCI.
14. Remover la BCI de la cabeza del paciente con las precauciones necesarias.

Nota: El protocolo desarrollado se basa en los protocolos de evaluación empleados por Adrian M. Owen para la valoración de sus pacientes en estados derivados del coma (Adrian M. Owen, 2006).

6. DISCUSIÓN DE RESULTADOS

Con el Emotiv EPOC se lograron captar las señales que permitieron caracterizar los patrones de activación definidos por los dos estados mentales propuestos: relajación y frustración. Posterior a la adquisición de estos registros, se aplicó la transformada de Fourier a estas señales con el fin de obtener las potencias en las diferentes bandas de frecuencia que se usaron como las variables predictoras del modelo.

El modelo planteado en el estudio se diseñó y desarrolló haciendo uso de las redes neuronales artificiales, las cuales fueron entrenadas de forma supervisada “OFF LINE” con una serie de pruebas destinadas para ello, proporcionando como resultado un aprendizaje eficiente sobre el cual se construyeron las ponderaciones sinápticas que posibilitaron la posterior validación de las mismas. En este sentido, el proceso de validación, empleando pruebas reservadas únicamente para este propósito, arrojó porcentajes de 76.67% y de 83.33% en el proceso de clasificación para la red neuronal perceptrón multicapa y para la red de base radial, respectivamente; lo que significa la clasificación correcta de por lo menos tres de cada cuatro casos.

Con el fin de emplear el modelo desarrollado satisfactoriamente con pacientes en estados derivados del coma, se planteó un protocolo de evaluación que tiene como fin, en una primera medida, posibilitar la inferencia del estado cognitivo de los pacientes, y en una segunda medida, la comunicación efectiva con éstos.

Se debe tener presente que los resultados arrojados por el modelo acerca de la inferencia del estado cognitivo no deben ser definitivos ya que hay una gran cantidad de factores subjetivos que se presentan en el momento de las valoraciones, que influyen desde la posibilidad que existe de que el paciente olvide cómo realizar una determinada tarea cognitiva, que no sea capaz de llevarla a cabo, o que simplemente la prueba realizada para una tarea tenga el efecto contrario, como podría presentarse en el caso del estado de relajación, en donde existe el riesgo de que el paciente genere patrones de activación opuestos de forma involuntaria. Así mismo se debe tener presente que los registros electroencefalográficos varían entre los diferentes pacientes, inclusive pueden variar en el mismo paciente, lo que conduce a una potencial variabilidad en los resultados entregados por el modelo.

7. CONCLUSIONES Y CONSIDERACIONES FINALES

El modelo planteado es efectivo para la clasificación de dos estados mentales en pacientes de control, lo que se traduce en la posibilidad de su implementación en pacientes en estados derivados del coma con el fin de inferir su estado cognitivo y propiciar una posterior comunicación con éstos según el protocolo determinado.

Existen diferentes factores de error que se pueden presentar durante la prueba que influyen en forma determinante en la calidad de los registros ingresados al modelo, tanto para los pacientes de control como para los pacientes en estados derivados del coma. Esto supone la necesidad de tomar medidas de precaución de modo que se asegure la adquisición correcta de los registros electroencefalográficos.

Los registros obtenidos mediante electroencefalografía requieren un preprocesamiento que involucra una serie de tratamientos como son los filtros y la remoción de artefactos, los cuales son necesarios para la correcta visualización, posterior empleo y análisis de los mismos.

Se determinó que, en general, la red de base radial se comporta de una mejor manera a la hora de clasificar diferentes pruebas en los estados mentales de relajación y frustración, clasificando correctamente cuatro de cada cinco pruebas.

La electroencefalografía incrementa substancialmente nuestro entendimiento de los pacientes con un severo daño cerebral mediante la adquisición de los registros de la actividad bioeléctrica cerebral y la determinación de patrones de activación cerebral diferentes que, a través de una evaluación exhaustiva, pueden llegar a sugerir el nivel de conciencia. Es de aclarar que la conciencia no es un fenómeno de todo o nada, como expresa el neurocientífico Adrian M. Owen, sino el resultado de la observación constante de diversos signos clínicos como respuesta ante estímulos externos que permiten la inferencia de un estado de conciencia.

BIBLIOGRAFÍA

- Adrian M. Owen, M. R. (2006). Detecting Awareness in the Vegetative State. *Sciencemag*, 1402.
- Alkire MT, H. R. (1995). Cerebral Metabolism during propofol anesthesia in humans studied positron emission tomography. *Anesthesiology*, 393-403.
- Alkire MT, P. C. (1999). Functional brain imaging during anesthesia in humans: effects of halothane on global and regional cerebral glucose metabolism. *Anesthesiology*, 701-09.
- Andre Mognon, J. J. (2011). Adjust: An automatic EEG artifact detector based on the joint use of spatial and temoral features. *Psychophysiology*, 48, 229-240.
- Athanasios Vourvopoulos, F. L. (s.f.). Brain-controlled NXT Robot: Tele-operating a robot through brain electrical.
- Bernt Schiele, R. B. (2010). *EEG Signal Processing and Emotiv's Neuro Headset*. Technische Universitat Darmstadt.
- Bertona, L. F. (Noviembre de 2005). Entrenamiento de Redes Neuronales Basado en Algoritmos Evolutivos. Buenos Aires, Argentina: Universidad de Buenos Aires.
- Bruce Stinson, D. A. (2013). A novel EEG for alpha brain state training, neruobiofeedback and behavior change. *Complementary Therapies in Clinical Practice 19 (Elsevier)*, 114-118.
- Buchsbaum MS, G. J. (1989). Regional cerebral glucose metabolic rate in human sleep assessed by positron emission tomography. *Life Sci*, 1349-56.
- Busch, N. (s.f.). *(Time-)Frequency Analysis of EEG Waveforms*. Charite University Medicine Berlin School of Mind and Brain.
- Christoph M. Michel, M. M. (2012). Towards the utilization of EEG as a brain imaging tool. *NeuroImage 61 (Elsevier)*, 371-385.
- Delorme, A. (s.f.). *Time-Frequency Analysis of Biophysical Time Series*.
- Dr Lisandro E. Olmos, D. M. (2012). Coma y estado vegetativo, las diferencias. *Entre Mujeres*.
- Emotiv. (7 de abril de 2013). Recuperado el 7 de abril de 2013, de <http://www.emotiv.com/>
- Española, R. A. (s.f.). Recuperado el 14 de abril de 2013, de <http://www.rae.es/rae.html>

- F. de Martino, F. G. (2007). Classification of fMRI independent componentes using IC-fingerprints and support vector machine classifiers. *Elsevier*, 177-194.
- Jackson, L. B. (1996). *Digital Filters and Signal Processing THIRD EDITION*. Kluwer Academic Publishers.
- Julie Onton, S. M. (2006). Information-based modeling of event-related brain dynamics. *Elsevier*.
- Lazarev, V. V. (1998). On the intercorrelation of some frequency and amplitude parameters of the human EEG and its functional significance. Communication I. *International Journal of Psychophysiology* 28, 77-98.
- LDI de la Universidad Carlos III de Madrid. (2013). Recuperado el Octubre de 2013, de <http://www.lab.inf.uc3m.es/~a0080630/redes-de-neuronas/>
- Majumdar, K. (2011). Human Scalp EEG processing: Various soft computing approaches. *Applied Soft Computing* 11 (Elsevier), 4433-4447.
- Maquet P, D. C. (1997). Functional neuroanatomy of human slow wave sleep. *J Neurosci*, 2807-12.
- Mathworks. (2013). Recuperado el Octubre de 2013, de <http://www.mathworks.com/help/signal/ref/periodogram.html>
- Matich, D. J. (Marzo de 2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Rosario, Argentina: Universidad Tecnológica Nacional.
- Nacional, U. T. (s.f.). Recuperado el 14 de abril de 2013, de http://dharma.frm.utn.edu.ar/cursos/ia/2012/material/APUNTES-FILMINAS/U4/redes_neuronales_artificiales.htm
- Nacional, U. T. (2013). *¿Qué son las redes neuronales artificiales?* Obtenido de http://dharma.frm.utn.edu.ar/cursos/ia/2012/material/APUNTES-FILMINAS/U4/redes_neuronales_artificiales.htm
- Navarro, R. B. (2010). *Electroencefalografía*. Madrid: Universidad de Alcalá.
- Neuroelectrics. (2013). *Neuroelectrics*. Obtenido de <http://neuroelectrics.com/>
- Neuroscience, S. C. (2013). *SCCN EEGLab*. Obtenido de <http://sccn.ucsd.edu/eeglab/>
- Neurosky. (7 de abril de 2013). Recuperado el 7 de abril de 2013, de <http://www.neurosky.com/>
- Olabe, X. B. (2013). *Redes Neuronales Artificiales y sus Aplicaciones*. Escuela Superior de Ingeniería de Bilbao.

- Pedro Isasi Viñuela, I. M. (2004). *Redes de Neuronas Artificiales: Un enfoque práctico*. Pearson.
- R.N. Khushaba, L. G. (2012). Choice Modeling and the Brain: A Study on the Electroencephalogram (EEG) of preferences. *Experts Systems with Applications (Elsevier)*, 39, 12378-12388.
- Rahman, M. (2011). *Applications of Fourier Transforms to Generalized Functions*. WIT Press.
- Rojas, D. H. (2010). *Control Mental de Vehiculos Teledirigidos*. Universidad de Málaga.
- Rojas, R. (1996). *Neural Networks: A Systematic Introduction*. Springer.
- Solomon Abramovich, A. T. (1990). *Electric response audiometry in clinical practice*. Edinburg: Churchill Livingstone.
- STATGRAPHICS. (2013).
- Steven Laureys, A. M. (2004). Brain Function in Coma, vegetative State, and Related Disorders. *The Lancet Neurology*, Vol 3, 537-547.
- Thilo Hinterberger, A. K. (2003). A brain-computer interface (BCI) for the locked in: comparison of different EEG classifications for the thought translation device. *Clinical Neurophysiology* 114 (Elsevier), 416-425.
- Thomas H. Budzynski, H. K. (2009). *Introduction to quantitative EEG and Neurofeedback*. Elsevier, Ed 2.
- Tzyy-Ping Jungl, C. H.-W. (1998). Extended ICA Removes Artifacts from Electroencephalographic Recordings. *Advances in Neural Information Processing Systems* 10, 894-900.
- Ubeyli, E. D. (2009). Statistics over features: EEG signals analysis. *Computers in Biology and Medicine* 39 (Elsevier), 733-741.
- Ubeyli, E. D. (2009). Analysis of EEG signals by implementing eigenvector methods/recurrent neural networks. *Digital Signal Processing* 19 (Elsevier), 134-143.
- V. Villanueva, A. G.-V. (2011). Utilidad de la monitorización Video-EEG en los pacientes con epilepsia farmacorresistente. *Science Direct*. Obtenido de <http://www.sciencedirect.com/recursosbiblioteca.eia.edu.co/science/article/pii/S2173580811700025>

ANEXOS

ANEXO 1. CRONOGRAMA

Fecha de Inicio:

14 de Julio

Fecha de Finalización:

31 de Octubre

Actividades	Semanas													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Caracterizar los patrones de entrada que muestran la presencia de conciencia.														
Investigar los diferentes tipos de headsets.														
Analizar los lenguajes de programación permitidos.														
Revisar los factores de error.														
Definir los estímulos adecuados.														
Diseñar el modelo que permita clasificar los patrones de activación cerebral.														
Obtener los registros regulares en pacientes conscientes.														
Plantear el modelo para clasificar los patrones de activación cerebral.														
Desarrollar el modelo propuesto en plataformas .NET.														
Realizar el modelo empleando los registros regulares de pacientes conscientes.														
Seleccionar el método más apropiado para evaluar a los pacientes.														
Plantear el protocolo para establecer las pruebas.														
Validar el modelo propuesto.														
Evaluar el aprendizaje de la red neuronal.														
Verificar el comportamiento de la red neuronal frente a los patrones de entrada.														
Validar el funcionamiento del modelo.														
Informes.														
Preparación del Informe Final.														
Entrega del Informe Intermedio.														
Entrega del Informe Final.														

ANEXO 2. PRESUPUESTO

RESUMEN DEL PRESUPUESTO

RUBROS	FUENTES		TOTAL
	EIA	Recursos propios	
PERSONAL	\$ 1,400,000	\$ 4,480,000	\$ 5,880,000
EQUIPOS Y SOFTWARE	\$ 2,800,000	\$ 600,000	\$ 3,400,000
MATERIALES, INSUMOS Y SERVICIOS TÉCNICOS	\$ 0	\$ 200,000	\$ 200,000
OTROS	\$ 0	\$ 16,000	\$ 16,000
ADMINISTRACIÓN			\$ 0
TOTAL	\$ 4,200,000	\$ 5,296,000	\$ 9,496,000.00

DETALLE DE GASTOS PERSONALES

NOMBRE	INSTITUCIÓN	FORMACIÓN ACADÉMICA	FUNCIÓN DENTRO DEL PROYECTO	DEDICACIÓN (horas/ semana)	SEMANAS	VALOR HORA	RECURSOS				TOTAL
						(\$)	EIA		Recursos propios		
							Especie	Dinero	Especie	Dinero	
Esteban Velásquez Rendón	EIA	Estudiante de Pregrado	Estudiante	20	14	\$ 8,000			\$ 2,240,000		\$ 2,240,000
Alejandro Cardona Murillo	EIA	Estudiante de Pregrado	Estudiante	20	14	\$ 8,000			\$ 2,240,000		\$ 2,240,000
Alejandro Peña Palacio	EIA	Doctorado	Director de Trabajo	2	14	\$ 25,000	\$ 700,000				\$ 700,000
Darío Jaramillo	EIA	Pregrado	Asesor	2	14	\$ 25,000	\$ 700,000				\$ 700,000
TOTAL							\$ 1,400,000	\$ 0	\$ 4,480,000	\$ 0	\$ 5,880,000

DETALLE DE EQUIPOS Y SOFTWARE QUE SE VAN A REQUERIR

DESCRIPCIÓN	JUSTIFICACIÓN Y MODALIDAD	CANTIDAD REQUERIDA	VALOR UNITARIO	TOTAL RECURSOS				TOTAL
			(\$)	EIA		Recursos propios		
				Especie	Dinero	Especie	Dinero	
Headset	Indispensable para registrar la actividad cerebral	1	\$ 1,400,000	\$ 1,400,000				
Licencia	Necesaria para trabajar con el headset	1	\$ 1,400,000	\$ 1,400,000				
Computador	Necesario para la redacción y elaboración de la tesis	2	\$ 300,000			\$ 600,000		\$ 600,000
TOTAL				\$ 2,800,000	\$ 0	\$ 600,000	\$ 0	\$ 3,400,000

DETALLE DE MATERIALES, INSUMOS Y SERVICIOS TÉCNICOS

DESCRIPCIÓN	JUSTIFICACIÓN	CANTIDAD REQUERIDA	VALOR UNITARIO	RECURSOS				TOTAL
			(\$)	EIA		Recursos propios		
				Especie	Dinero	Especie	Dinero	
Papelería	Para impresión de la tesis y de los resultados de las pruebas	1	\$ 200,000			\$ 200,000		\$ 200,000
TOTAL						\$ 200,000	\$ -	\$ 200,000

DETALLE OTROS RUBROS

DESCRIPCIÓN	JUSTIFICACIÓN	CANTIDAD REQUERIDA	VALOR UNITARIO	RECURSOS				TOTAL
			(\$)	EIA		Recursos propios		
				Especie	Dinero	Especie	Dinero	
Transporte	Gastos viáticos	10	\$ 1,600				\$ 16,000	\$ 16,000
TOTAL							\$ 16,000	\$ 16,000

ANEXO 3. PROGRAMACIÓN EN VISUAL BASIC DE LA RED PERCEPTRÓN MULTICAPA

Figura 26. Interfaz gráfica de las dos redes neuronales.

```
Public Class frmHome
    'Se declaran las variables a utilizar:
    Public OXL, OWB As Object
    Public Ruta As String
    Dim i,j,i1,ND,NP,NE,k,NIT As Integer
    Public X(,),W(,),S(,),C(,),yr(),yd(),erk(),alfa,ERS(),N,NVD As Single

    Private Sub btnConexion_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles btnConexion.Click
        'Se establece la comunicación con Excel:
        Ruta = Application.StartupPath
        OXL = CreateObject("Excel.Application")
        OWB = OXL.Workbooks.Open(Ruta & "\Decodificador")
        OXL.Visible = True
        Me.Activate()

    End Sub

    Private Sub btnIdentificacion_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles btnIdentificacion.Click
        'Se ingresan de parámetros iniciales
        ND = Val(txtND.Text)          'Número de datos
        NE = Val(txtNE.Text)          'Número neuronas en la capa de entrada
```

```

NP = Val(txtNP.Text)           'Número de neuronas en la capa oculta
NIT = Val(txtNIT.Text)        'Número máximo de iteraciones
alfa = Val(txtAlfa.Text)      'Factor de aprendizaje

'Se redimensiona el tamaño de las matrices y los vectores

ReDim X(ND, NE), W(NP, NE), S(NP), yr(ND)
ReDim C(NP), yd(ND), erk(ND), ERS(NIT)

'Se leen los datos de entrada y de salida
Randomize()
For Me.k = 1 To ND - ND * (txtPorcentajeValid.Text / 100)
    For Me.i = 1 To NE
        X(k, i) = Val(OWB.Worksheets(1).cells(k + 1, i + 1).value) 'Series
de datos de entrada
    Next i
    yd(k) = Val(OWB.Worksheets(1).cells(k + 1, i + 1).value) 'Series
de datos de salida (esperada)
Next k

'Se generan los pesos aleatoriamente
For Me.j = 1 To NP
    For Me.i = 0 To NE
        W(j, i) = (-1 + 2 * Rnd()) / 100 'Pesos entre la capa de entrada y
la capa oculta
    Next i
    C(j) = (-1 + 2 * Rnd()) / 100 'Pesos entre la capa oculta y la
capa de salida
Next j

'Proceso Feedforward
For Me.i1 = 1 To NIT
    txtIteracion.Text = i1
    For Me.k = 1 To ND - ND * (txtPorcentajeValid.Text / 100)

        'Se procesan los datos de entrada
        yr(k) = 0
        For Me.j = 1 To NP
            S(j) = 0
            For Me.i = 1 To NE
                S(j) = S(j) + X(k, i) * W(j, i) 'Entradas Ponderadas
            Next i
            yr(k) = yr(k) + C(j) * S(j) 'Salida aprendida
        Next j

        'Se imprime la salida aprendida en la iteración actual
        If yr(k) < 0.5 And yr(k) > -0.5 Then
            OWB.Worksheets(1).cells(k + 1, NE + 3).value = 0
        ElseIf yr(k) > 0.5 And yr(k) < 1.5 Then
            OWB.Worksheets(1).cells(k + 1, NE + 3).value = 1
        End If

        'Se calcula el error entre la salida esperada y la salida aprendida
        erk(k) = yd(k) - yr(k)
    
```

```

        'Se calcula el error cuadrático medio (MSE)
        ERS(i1) = ERS(i1) + ((erk(k)) ^ 2) / 2

        'Proceso Backpropagation (Actualización de los pesos)
        For Me.j = 1 To NP
            C(j) = C(j) + alfa * erk(k) * S(j)
            For Me.i = 0 To NE
                W(j, i) = W(j, i) + (C(j) * erk(k)) * alfa * X(k, i)
            Next i
        Next j
    Next k

    'Se imprime la iteración y el MSE actual
    OXL.worksheets(2).cells(i1 + 1, 1).value = i1
    OXL.worksheets(2).cells(i1 + 1, 2).value = ERS(i1)
    txtERS.Text = ERS(i1)

    'Evaluación de los criterios de parada
    If ERS(i1) <= 0.005 Then
        MsgBox("Finalizo el entrenamiento en la iteración " & i1)
        i1 = NIT
    End If
    If ERS(i1) - ERS(i1 - 1) > 0 And i1 > 5 Then
        MsgBox("Finalizo el entrenamiento en la iteración " & i1)
        i1 = NIT
    End If
Next i1

'Se imprimen los pesos construidos durante el proceso aprendizaje
For Me.j = 1 To NP
    For Me.i = 0 To NE
        OWB.Worksheets(2).cells(j + 1, i + 13).value = W(j, i)
    Next i
    OWB.Worksheets(2).cells(j + 1, i + 12).value = C(j)
Next j

OWB.Application.MaxChange = 0.001
End Sub

Private Sub btnSalir_Click(ByVal sender As System.Object, ByVal e As System.EventArgs)
Handles btnSalir.Click
    'Boton para salir del programa
    Try
        'OWB.Save()
        OWB.Close(False)
        OWB = Nothing
        OXL.Quit()
        OXL = Nothing
    Catch ex As Exception

    End Try
    Application.Exit()
End Sub

```

```

Private Sub btnValidacion_Click(sender As Object, e As EventArgs) Handles
btnValidacion.Click
    'Proceso Feedforward para validar con los pesos construidos
    NDV = ND - (txtPorcentajeValid.Text) / 100 * ND + 1
    For Me.k = 1 To ND * (txtPorcentajeValid.Text / 100)
        For Me.i = 1 To NE
            X(k, i) = Val(OWB.Worksheets(1).cells(k + NDV, i + 1).value)
        Next i
        yd(k) = Val(OWB.Worksheets(1).cells(k + NDV + 1, i + 1).value)
    Next k
    For Me.k = 1 To ND * (txtPorcentajeValid.Text / 100)
        yr(k) = 0
        For Me.j = 1 To NP
            S(j) = 0
            For Me.i = 1 To NE
                S(j) = S(j) + X(k, i) * W(j, i)
            Next i
            yr(k) = yr(k) + C(j) * S(j)
        Next j
    Next k

    'Se imprime la salida generada por la red en la iteración actual
    If yr(k) < 0.5 And yr(k) > -0.5 Then
        OWB.Worksheets(1).cells(k + NDV, NE + 3).value = 0
    ElseIf yr(k) > 0.5 And yr(k) < 1.5 Then
        OWB.Worksheets(1).cells(k + NDV, NE + 3).value = 1
    End If
Next k
End Sub
End Class

```

ANEXO 4. PROGRAMACIÓN EN VISUAL BASIC DE LA RED DE BASE RADIAL

```
Public Class frmHome
    'Se declaran las variables a utilizar:
    Public OXL, OWB As Object
    Public Ruta As String
    Dim i,j,i1,ND,NP,NE,k,NIT As Integer
    Public X(,),XC(,),S(,),C(,),yr(,),yd(,),erk(,),alfa,ERS(,),N,NVD,h() As Single

    Private Sub btnConexion_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles btnConexion.Click
        'Se establece la comunicación con Excel:
        Ruta = Application.StartupPath
        OXL = CreateObject("Excel.Application")
        OWB = OXL.Workbooks.Open(Ruta & "\Decodificador")
        OXL.Visible = True
        Me.Activate()

    End Sub

    Private Sub btnIdentificacion_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles btnIdentificacion.Click
        'Se ingresan de parámetros iniciales
        ND = Val(txtND.Text)
        NE = Val(txtNE.Text)
        NP = Val(txtNP.Text)
        NIT = Val(txtNIT.Text)
        alfa = Val(txtAlfa.Text)

        'Se redimensiona el tamaño de las matrices y los vectores
        ReDim X(ND, NE), XC(NP, NE), S(NP), yr(ND), h(NP)
        ReDim C(NP), yd(ND), erk(ND), ERS(NIT)

        'Se leen los datos de entrada y de salida
        Randomize()
        For Me.k = 1 To ND - ND * (txtPorcentajeValid.Text / 100)
            For Me.i = 1 To NE
                X(k, i) = Val(OWB.Worksheets(1).cells(k + 1, i + 1).value) 'Series
de datos de entrada
            Next i
            yd(k) = Val(OWB.Worksheets(1).cells(k + 1, i + 1).value) 'Series
de datos de salida (esperada)
        Next k

        'Se generan los pesos aleatoriamente
        For Me.j = 1 To NP
            For Me.i = 0 To NE
                XC(j, i) = (-1 + 2 * Rnd()) / 100 'Centros de la red de base radial
            Next i
            C(j) = (-1 + 2 * Rnd()) / 100
        Next j

        'Paso 1: Iniciamos el proceso de aprendizaje (Proceso Feedforward)
        For Me.i1 = 1 To NIT
            txtIteracion.Text = i1
        Next i1
    End Sub
End Class
```

```

For Me.k = 1 To ND - ND * (txtPorcentajeValid.Text / 100)

    'Se procesan los datos de entrada
    yr(k) = 0

    For Me.j = 1 To NP
        S(j) = 0 : h(j) = 0
        For Me.i = 1 To NE
            S(j) = S(j) + (X(k, i) - XC(j, i)) ^ 2 'Entradas Ponderadas
        Next i
        h(j) = Math.Exp(-0.5 * S(j)) 'Función de activación de base radial
gaussiana

        yr(k) = yr(k) + C(j) * h(j) 'Salida aprendida
    Next j

    'Se imprime la salida aprendida en la iteración actual
    If yr(k) < 0.5 And yr(k) > -0.5 Then
        OWB.Worksheets(1).cells(k + 1, NE + 3).value = 0
    ElseIf yr(k) > 0.5 And yr(k) < 1.5 Then
        OWB.Worksheets(1).cells(k + 1, NE + 3).value = 1
    End If

    'Se calcula el error entre la salida esperada y la salida aprendida
    erk(k) = yd(k) - yr(k)

    'Se calcula el error cuadrático medio (MSE)
    ERS(i1) = ERS(i1) + ((erk(k)) ^ 2) / 2

    'Proceso Backpropagation (Actualización de los pesos)
    For Me.j = 1 To NP
        C(j) = C(j) + alfa * erk(k) * h(j)
        For Me.i = 0 To NE
            XC(j, i) = XC(j, i) + (C(j) * erk(k)) * alfa * 2 * h(j) * (X(k, i) - XC(j,
i))
        Next i
    Next j
Next k

'Se imprime la iteración y el MSE actual
OXL.worksheets(2).cells(i1 + 1, 1).value = i1
OXL.worksheets(2).cells(i1 + 1, 2).value = ERS(i1)
txtERS.Text = ERS(i1)

'Evaluación de los criterios de parada
If ERS(i1) <= 0.005 Then
    MsgBox("Finalizo el entrenamiento en la iteración " & i1)
    i1 = NIT
End If
If ERS(i1) - ERS(i1 - 1) > 0 And i1 > 5 Then
    MsgBox("Finalizo el entrenamiento en la iteración " & i1)
    i1 = NIT
End If
Next i1

'Se imprimen los pesos construidos durante el proceso aprendizaje

```

```

For Me.j = 1 To NP
    For Me.i = 0 To NE
        OWB.Worksheets(2).cells(j + 1, i + 13).value = XC(j, i)
    Next i
    OWB.Worksheets(2).cells(j + 1, i + 12).value = C(j)
Next j

OWB.Application.MaxChange = 0.001
End Sub

Private Sub btnSalir_Click(ByVal sender As System.Object, ByVal e As System.EventArgs)
Handles btnSalir.Click
    'Boton para salir del programa
    Try
        'OWB.Save()
        OWB.Close(False)
        OWB = Nothing
        OXL.Quit()
        OXL = Nothing
    Catch ex As Exception
    End Try
    Application.Exit()
End Sub

Private Sub btnValidacion_Click(sender As Object, e As EventArgs) Handles
btnValidacion.Click
    'Proceso Feedforward para validar con los pesos contruidos
    NDV = ND - (txtPorcentajeValid.Text) / 100 * ND + 1 'Numero de Datos a Validar
    For Me.k = 1 To ND * (txtPorcentajeValid.Text / 100) + 1
        For Me.i = 1 To NE
            X(k, i) = Val(OWB.Worksheets(1).cells(k + NDV, i + 1).value)
        Next i
        yd(k) = Val(OWB.Worksheets(1).cells(k + NDV + 1, i + 1).value)
    Next k
    For Me.k = 1 To (ND * (txtPorcentajeValid.Text / 100))
        yr(k) = 0
        For Me.j = 1 To NP
            S(j) = 0
            For Me.i = 1 To NE
                S(j) = S(j) + (X(k, i) - XC(j, i)) ^ 2
            Next i
            h(j) = Math.Exp(-0.5 * S(j))
            yr(k) = yr(k) + C(j) * h(j)
        Next j

        'Se imprime la salida generada por la red en la iteración actual
        If yr(k) < 0.5 And yr(k) > -0.5 Then
            OWB.Worksheets(1).cells(k + NDV, NE + 3).value = 0
        ElseIf yr(k) > 0.5 And yr(k) < 1.5 Then
            OWB.Worksheets(1).cells(k + NDV, NE + 3).value = 1
        End If
    Next k
End Sub
End Class

```


ANEXO 5. PROGRAMACIÓN EN MATLAB

- **Cálculo del espectro de potencia y de la potencia en las diferentes bandas de frecuencia:**

%La entrada (X[,]) es la matriz en el dominio del tiempo de las magnitudes en voltaje de cada electrodo en las diferentes muestras de tiempo. Las salidas son: la potencia en dB*W (Plog[,]) en el dominio de la frecuencia, la potencia en cada banda de frecuencia (M[,]) y el promedio total de la potencia de cada banda de frecuencia que se registró en los todos los electrodos (PROMEDIOTOTAL[]).

```
function [Plog,M,PROMEDIOTOTAL] = POTENCIA( X )
clc
%Se ingresa la frecuencia de muestreo
Fs=128;
NFFT = length(X(:,1));
for i=1:14
    %Se calcula el espectro de potencia en todo el rango de frecuencias.
    [P(:,i),F(:,i)] = pwelch(X(:,i),hann(NFFT),0,NFFT,Fs,'power');
    %Se calcula el espectro de potencia de cada banda de frecuencia
    M(1,i) = 10*log10(bandpower(X(:,i),Fs,[1 4]));      %Delta
    M(2,i) = 10*log10(bandpower(X(:,i),Fs,[4 8]));      %Thetta
    M(3,i) = 10*log10(bandpower(X(:,i),Fs,[8 12]));     %Alpha
    M(4,i) = 10*log10(bandpower(X(:,i),Fs,[12 30]));    %Beta
    M(5,i) = 10*log10(bandpower(X(:,i),Fs,[30 50]));    %Gamma
end
%Se grafican todos los espectros de potencia resultantes de todos los
electrodo
figure(1);
plot(F(:,1),10*log10(P(:,1)),'b-','LineWidth',2)
hold on
plot(F(:,2),10*log10(P(:,2)),'g-','LineWidth',2)
plot(F(:,3),10*log10(P(:,3)),'r-','LineWidth',2)
plot(F(:,4),10*log10(P(:,4)),'c-','LineWidth',2)
plot(F(:,5),10*log10(P(:,5)),'m-','LineWidth',2)
plot(F(:,6),10*log10(P(:,6)),'y-','LineWidth',2)
plot(F(:,7),10*log10(P(:,7)),'b--','LineWidth',2)
plot(F(:,9),10*log10(P(:,9)),'g--','LineWidth',2)
plot(F(:,10),10*log10(P(:,10)),'r--','LineWidth',2)
plot(F(:,11),10*log10(P(:,11)),'c--','LineWidth',2)
plot(F(:,12),10*log10(P(:,12)),'m--','LineWidth',2),'k-','LineWidth',2)
plot(F(:,8),10*log10(P(:,8))
plot(F(:,13),10*log10(P(:,13)),'y--','LineWidth',2)
plot(F(:,14),10*log10(P(:,14)),'k--','LineWidth',2)
title('Espectro de Potencia de cada Electrodo')
xlabel('Frecuencia (Hz)')
ylabel('Potencia (dbW)')
%Se grafica el espectro de potencia de cada electrodo por aparte
figure(2);
subplot(3,5,1)
plot(F(:,1),10*log10(P(:,1)),'b-','LineWidth',2)
title('AF3')
```

```

subplot(3,5,2)
plot(F(:,2),10*log10(P(:,2)), 'g-', 'LineWidth',2)
title('F7')
subplot(3,5,3)
plot(F(:,3),10*log10(P(:,3)), 'r-', 'LineWidth',2)
title('F3')

subplot(3,5,4)
plot(F(:,4),10*log10(P(:,4)), 'c-', 'LineWidth',2)
title('FC5')
subplot(3,5,5)
plot(F(:,5),10*log10(P(:,5)), 'm-', 'LineWidth',2)
title('T7')
subplot(3,5,6)
plot(F(:,6),10*log10(P(:,6)), 'y-', 'LineWidth',2)
title('P7')
subplot(3,5,7)
plot(F(:,7),10*log10(P(:,7)), 'k-', 'LineWidth',2)
title('O1')
subplot(3,5,8)
plot(F(:,8),10*log10(P(:,8)), 'b--', 'LineWidth',2)
title('O2')
subplot(3,5,9)
plot(F(:,9),10*log10(P(:,9)), 'g--', 'LineWidth',2)
title('P8')
subplot(3,5,10)
plot(F(:,10),10*log10(P(:,10)), 'r--', 'LineWidth',2)
title('T8')
subplot(3,5,11)
plot(F(:,11),10*log10(P(:,11)), 'c--', 'LineWidth',2)
title('FC6')
subplot(3,5,12)
plot(F(:,12),10*log10(P(:,12)), 'm--', 'LineWidth',2)
title('F4')
subplot(3,5,13)
plot(F(:,13),10*log10(P(:,13)), 'y--', 'LineWidth',2)
title('F8')
subplot(3,5,14)
plot(F(:,14),10*log10(P(:,14)), 'k--', 'LineWidth',2)
title('AF4')

%Se convierten las potencias calculadas en escala dB*W
Plog=10*log10(P(:,:));
%Se calcula el promedio de las potencias de cada banda de frecuencia en los
diferentes electrodos
for j=1:5
    PROMEDIOTOTAL(j)=mean(M(j,:));
end
end

```



ESCUELA DE INGENIERÍA DE ANTIOQUIA

ACTA DE EVALUACIÓN FINAL DE TRABAJO DE GRADO

Fecha: (dd /mm / aa)	/11/ 2013						
Nombre del Proyecto:	Modelo para determinar el estado cognitivo en pacientes comatosos mediante el registro de la actividad dieléctrica cerebral /11/2013						
Nombre del Director:	Juan Alejandro Peña Palacio						
<table border="1"> <tr> <td>Nombre del estudiante</td> <td>Programa académico</td> </tr> <tr> <td>Alejandro Cardona Murillo</td> <td>Ingeniería Mecatrónica</td> </tr> <tr> <td>Esteban Velásquez Rendón</td> <td>Ingeniería Mecatrónica</td> </tr> </table>		Nombre del estudiante	Programa académico	Alejandro Cardona Murillo	Ingeniería Mecatrónica	Esteban Velásquez Rendón	Ingeniería Mecatrónica
Nombre del estudiante	Programa académico						
Alejandro Cardona Murillo	Ingeniería Mecatrónica						
Esteban Velásquez Rendón	Ingeniería Mecatrónica						
Nombre del Jurado:	Luis Germán G. - Juan Sebastián B.						
Evaluación del proyecto: Espacio exclusivo para jurado							
<input type="checkbox"/> No aprobado <input checked="" type="checkbox"/> Aprobado sin mención <input type="checkbox"/> con Mención Pública <input type="checkbox"/> con Mención honorífica <input type="checkbox"/> Trabajo laureado							
Justificación del reconocimiento: (Artículo 28 del Acuerdo 11: "El director del Programa presentará el acta final de evaluación al Consejo Académico, donde consta la solicitud de mención especial debidamente justificada y el Consejo determinará si se otorga o no")							

DIRECTOR DEL PROGRAMA

DIRECTOR DEL TRABAJO DE GRADO

JURADO (Si lo hubo)

DIRECTOR DE PROGRAMA